

BUNDESREPUBLIK DEUTSCHLAND

PRIORITY
DOCUMENTSUBMITTED OR TRANSMITTED IN
COMPLIANCE WITH RULE 17.1(a) OR (b)

REC'D	26 JUL 2000
WIPO	PCT

EJU

Prioritätsbescheinigung über die Einreichung
einer Patentanmeldung

DE 00/01764

Aktenzeichen: 199 28 776.7
Anmeldetag: 23. Juni 1999
Anmelder/Inhaber: Siemens Aktiengesellschaft,
München/DE
Bezeichnung: Anordnung und Verfahren sowie Computer-
programm-Erzeugnis und computerlesbares
Speichermedium zur rechnergestützten Kompen-
sation eines Ungleichgewichtszustands eines tech-
nischen Systems
IPC: G 06 F 17/00

Die angehefteten Stücke sind eine richtige und genaue Wiedergabe der ur-
sprünglichen Unterlagen dieser Anmeldung.

München, den 06. Juli 2000
Deutsches Patent- und Markenamt

Der Präsident
Im Auftrag

Agurka

This Page Blank (uspto)

**Beschreibung**

5 **Anordnung und Verfahren sowie Computerprogramm-Erzeugnis und computerlesbares Speichermedium zur rechnergestützten Kompen-
sation eines Ungleichgewichtszustands eines technischen Sy-
stems**

10 Die Erfindung betrifft eine Anordnung, ein Verfahren, ein Computerprogramm-Erzeugnis und ein computerlesbares Speicher-
medium zur rechnergestützten Kompensation eines Ungleichge-
wichtszustands eines technischen Systems.

15 Aus [1] ist es bekannt, zur Ermittlung von Zuständen eines dynamischen Systems und einer Dynamik, die einem dynamischen System zugrunde liegt, ein neuronales Netz einzusetzen.

20 Allgemein wird ein dynamischer Prozeß, der in einem dynamischen System abläuft, üblicherweise durch eine Zustandsüber-
gangsbeschreibung, die für einen Beobachter des dynamischen Prozesses nicht sichtbar ist, und eine Ausgangsgleichung, die beobachtbare Größen des technischen dynamischen Prozesses be-
schreibt, beschrieben.

Eine solche Struktur ist in Fig. 7 dargestellt.

Ein dynamisches System 700 unterliegt dem Einfluß einer ex-
ternen Eingangsgröße u vorgebbarer Dimension, wobei eine Ein-
gangsgröße u_t zu einem Zeitpunkt t mit u_t bezeichnet wird:

30 $u_t \in \mathbb{R}^l$,

wobei mit l eine natürliche Zahl bezeichnet wird.

35 Die Eingangsgröße u_t zu einem Zeitpunkt t verursacht eine Veränderung des dynamischen Prozesses, der in dem dynamischen System 700 abläuft.

Ein innerer Zustand s_t ($s_t \in \mathbb{R}^m$) vorgebbarer Dimension m zu einem Zeitpunkt t ist für einen Beobachter des dynamischen Systems 200 nicht beobachtbar.

5 In Abhängigkeit vom inneren Zustand s_t und der Eingangsgröße u_t wird ein Zustandsübergang des inneren Zustandes s_t des dynamischen Prozesses verursacht und der Zustand des dynamischen Prozesses geht über in einen Folgezustand s_{t+1} zu einem folgenden Zeitpunkt $t+1$.

10

Dabei gilt:

$$s_{t+1} = f(s_t, u_t). \quad (1)$$

15 wobei mit $f(\cdot)$ eine allgemeine Abbildungsvorschrift bezeichnet wird.

20 Eine von einem Beobachter des dynamischen Systems 700 beobachtbare Ausgangsgröße y_t zu einem Zeitpunkt t hängt ab von der Eingangsgröße u_t sowie dem inneren Zustand s_t .

Die Ausgangsgröße y_t ($y_t \in \mathbb{R}^n$) ist vorgebbarer Dimension n .

25 Die Abhängigkeit der Ausgangsgröße y_t von der Eingangsgröße u_t und dem inneren Zustand s_t des dynamischen Prozesses ist durch folgende allgemeine Vorschrift gegeben:

$$y_t = g(s_t, u_t), \quad (2)$$

30 wobei mit $g(\cdot)$ eine allgemeine Abbildungsvorschrift bezeichnet wird.

35 Zur Beschreibung des dynamischen Systems 700 wird in [1] eine Anordnung miteinander verbundener Rechenelemente in Form eines neuronalen Netzes miteinander verbundener Neuronen eingesetzt. Die Verbindungen zwischen den Neuronen des neuronalen

Netze sind gewichtet. Die Gewichte des neuronalen Netzes sind in einem Parametervektor v zusammengefaßt.

Somit hängt ein innerer Zustand eines dynamischen Systems, 5 welches einem dynamischen Prozeß unterliegt, gemäß folgender Vorschrift von der Eingangsgröße u_t und dem inneren Zustand des vorangegangenen Zeitpunktes s_t und dem Parametervektor v ab:

$$10 \quad s_{t+1} = \text{NN}(v, s_t, u_t), \quad (3)$$

wobei mit $\text{NN}(\cdot)$ eine durch das neuronale Netz vorgegebene Abbildungsvorschrift bezeichnet wird.

15 Die aus [1] bekannte und als Time Delay Recurrent Neural Network (TDRNN) bezeichnete Anordnung wird in einer Trainingsphase derart trainiert, daß zu einer Eingangsgröße u_t jeweils eine Zielgröße y_t^d an einem realen dynamischen System ermittelt wird. Das Tupel (Eingangsgröße, ermittelte Zielgröße) 20 wird als Trainingsdatum bezeichnet. Eine Vielzahl solcher Trainingsdaten bilden einen Trainingsdatensatz.

Mit dem Trainingsdatensatz wird das TDRNN trainiert. Eine Übersicht über verschiedene Trainingsverfahren ist ebenfalls 5 in [1] zu finden.

Es ist an dieser Stelle zu betonen, daß lediglich die Ausgangsgröße y_t zu einem Zeitpunkt t des dynamischen Systems 700 erkennbar ist. Der innere Systemzustand s_t ist nicht beobachtbar.

In der Trainingsphase wird üblicherweise folgende Kostenfunktion E minimiert:

$$35 \quad E = \frac{1}{T} \sum_{t=1}^T (y_t - y_t^d)^2 \rightarrow \min_{f,g} \quad (4)$$

wobei mit T eine Anzahl berücksichtigter Zeitpunkte bezeichnet wird.

5 Aus [2] ist eine Anordnung mehrerer miteinander verbundener neuronaler Netze bekannt.

Bei der aus [2] bekannten Anordnung sind mehrere hierarchisch strukturierte neuronale Teilnetze im Rahmen eines sogenannten 10 Gating-Netzwerks in einer parallelen Anordnung zueinander in einer Gesamtstruktur verknüpft.

Bei dem Gating-Netzwerk wird den neuronalen Teilnetzen jeweils ein gleicher Eingabevektor zugeführt. Die neuronalen 15 Teilnetze ermitteln entsprechend ihrer internen Struktur jeweils einen Ausgabevektor. Die Ausgabevektoren der neuronalen Teilnetze werden gewichtet linear aufsummiert.

Ein Trainingsverfahren für das Gating-Netzwerk ist ebenfalls 20 in [2] genannt.

Die bekannten Anordnungen und Verfahren weisen insbesondere den Nachteil auf, daß eine Identifikation bzw. Modellierung eines dynamischen Systems und eine Ermittlung von Zuständen 25 eines dynamischen Systems nur mit unzureichender Genauigkeit möglich ist.

Somit liegt der Erfindung das Problem zugrunde, eine Anordnung anzugeben, mit der eine Modellierung eines dynamischen 30 Systems und die Ermittlung eines Zustands des dynamischen Systems möglich ist und welche Anordnung die Modellierung und die Ermittlung mit einer größeren Genauigkeit als bei den bekannten Anordnungen ermöglicht.

35 Ferner liegt der Erfindung das Problem zugrunde, ein Verfahren, ein Computerprogramm-Erzeugnis und ein computerlesbares Speichermedium anzugeben, mit welchen eine Modellierung eines

dynamischen Systems und die Ermittlung eines Zustands des dynamischen Systems möglich ist und welche die Modellierung und die Ermittlung mit einer größeren Genauigkeit als bei den bekannten Anordnungen ermöglichen.

5

Die Probleme werden durch die Anordnung sowie die Verfahren mit den Merkmalen gemäß den unabhängigen Ansprüchen gelöst.

10 Eine Anordnung zur rechnergestützten Kompensation eines Ungleichgewichtszustands eines ersten technischen Systems, umfaßt ein erstes neuronales Netz, welches das erste technische System beschreibt sowie ein zweites neuronales Netz, welches ein zweites technisches System beschreibt. Das erste und das zweite neuronale Netz sind derart miteinander verbunden, daß 15 ein Ungleichgewichtszustand des ersten technischen Systems durch das zweite neuronale Netz kompensierbar ist.

20 Bei einem Verfahren zur rechnergestützten Kompensation eines Ungleichgewichtszustands eines ersten technischen Systems wird einem ersten neuronalen Netz, welches das erste technische System beschreibt, eine erste Eingangsgröße zugeführt. Für die erste Eingangsgröße wird unter Verwendung des ersten neuronalen Netzes eine erste Ausgangsgröße ermittelt, welche 25 einen Ungleichgewichtszustand des ersten technischen Systems beschreibt. Die erste Ausgangsgröße wird als eine zweite Eingangsgröße einem zweiten neuronalen Netz zugeführt, welches ein zweites technisches System beschreibt. Für die zweite Eingangsgröße wird unter Verwendung des zweiten neuronalen Netzes eine zweite Ausgangsgröße, welche einen Zustand des 30 zweiten technischen Systems beschreibt, derart ermittelt, daß der Ungleichgewichtszustand des ersten technischen Systems durch das zweite neuronale Netz kompensiert wird.

35 Ein Computerprogramm-Erzeugnis, das ein computerlesbares Speichermedium umfaßt, auf dem ein Programm gespeichert ist, ermöglicht einem Computer, nachdem es in einen Speicher des Computer geladen worden ist, folgende Schritte durchzuführen

zur rechnergestützten Kompensation eines Ungleichgewichtszustands eines ersten technischen Systems:

- einem ersten neuronalen Netz, welches das erste technische System beschreibt, wird eine erste Eingangsgröße zugeführt;
- 5 - für die erste Eingangsgröße wird unter Verwendung des ersten neuronalen Netzes eine erste Ausgangsgröße ermittelt, welche einen Ungleichgewichtszustand des ersten technischen Systems beschreibt;
- die erste Ausgangsgröße wird als eine zweite Eingangsgröße 10 einem zweiten neuronalen Netz zugeführt, welches ein zweites technisches System beschreibt;
- für die zweite Eingangsgröße wird unter Verwendung des zweiten neuronalen Netzes eine zweite Ausgangsgröße, welche 15 einen Zustand des zweiten technischen Systems beschreibt, derart ermittelt, daß der Ungleichgewichtszustand des ersten technischen Systems durch das zweite neuronale Netz kompensiert wird.

20 Ein computerlesbares Speichermedium, auf dem ein Programm gespeichert ist, ermöglicht einem Computer, nachdem es in einen Speicher des Computer geladen worden ist, folgende Schritte durchzuführen zur rechnergestützten Kompensation eines Ungleichgewichtszustands eines ersten technischen Systems:

- einem ersten neuronalen Netz, welches das erste technische System beschreibt, wird eine erste Eingangsgröße zugeführt;
- für die erste Eingangsgröße wird unter Verwendung des ersten neuronalen Netzes eine erste Ausgangsgröße ermittelt, welche einen Ungleichgewichtszustand des ersten technischen Systems beschreibt;
- 25 - die erste Ausgangsgröße wird als eine zweite Eingangsgröße einem zweiten neuronalen Netz zugeführt, welches ein zweites technisches System beschreibt;
- für die zweite Eingangsgröße wird unter Verwendung des zweiten neuronalen Netzes eine zweite Ausgangsgröße, welche 30 einen Zustand des zweiten technischen Systems beschreibt, derart ermittelt, daß der Ungleichgewichtszustand des ersten

technischen Systems durch das zweite neuronale Netz kompensiert wird.

Unter einem Ungleichgewichtszustand eines Systems ist ein Zustand des Systems zu verstehen, der hinsichtlich vorgebbarer Kriterien nicht einem ausgewählten Zustand des Systems, dem Gleichgewichtszustand, entspricht.

Der Gleichgewichtszustand des Systems kann sich beispielsweise dadurch auszeichnen, daß das System in diesem Zustand Stabilität oder Effektivität hinsichtlich eines Übertragungsverhaltens des Systems aufweist.

Die Erfindung weist den besonderen Vorteil auf, daß für ein Training der Anordnung eine geringe Anzahl von Trainingsdaten notwendig ist, um unter Verwendung der trainierten Anordnung eine Modellierung eines dynamischen Systems und die Ermittlung eines Zustands des dynamischen Systems mit hinreichender Genauigkeit durchzuführen zu können.

Bevorzugte Weiterbildungen der Erfindung ergeben sich aus den abhängigen Ansprüchen.

Die im weiteren beschriebenen Weiterbildungen beziehen sich sowohl auf das Verfahren, die Anordnung sowie auf das Computerprogramm-Erzeugnis und das computerlesbare Speichermedium.

Die Erfindung und die im weiteren beschriebenen Weiterbildungen können sowohl in Software als auch in Hardware, beispielsweise unter Verwendung einer speziellen elektrischen Schaltung realisiert werden.

Das erste neuronale Netz kann derart realisiert werden, daß es zumindest ein erstes Eingangs-Rechenelement und ein erstes Ausgangs-Rechenelement aufweist.

Entsprechendes gilt für eine Realisierung des zweiten neuro-nale Netzes.

5 Bevorzugt sind zumindest ein Teil der Rechenelemente künstli-che Neuronen.

Zu einer Vereinfachung eines Trainings einer Realisierung der Erfindung ist mindestens ein Teil von Verbindungen zwischen Rechenelementen variabel ausgestaltet.

10

In einer weiteren Ausgestaltung weisen zumindest Teile der Verbindungen gleiche Gewichtswerte auf.

15 Zu einer Vereinfachung bei einer Beschreibung eines komplexen Gesamtsystems ist es günstig das komplexe Gesamtsystem derart zu strukturieren, daß das erste technische System und das zweite technische System jeweils ein Teilsystem des komplexen Gesamtsystems beschreiben.

20 Ferner kann aber auch das erste technische System und das zweite technische System identisch sein.

25 Da durch die Erfindung eine Modellierung eines dynamischen Systems mit hinreichender Genauigkeit möglich ist, wird eine Realisierung bevorzugt zur Ermittlung einer Dynamik eines Sy-
stems eingesetzt.

30 Ferner wird eine Ausgestaltung eingesetzt zu einer Prognose eines zukünftigen Zustands eines Systems sowie zu einer Über-wachung und/oder Steuerung eines Systems.

Bevorzugt ist das System ein chemischer Reaktor.

35 Ausführungsbeispiele der Erfindung sind in den Figuren darge-stellt und werden im weiteren näher erläutert:

Es zeigen

Figur 1 eine Skizze eines chemischen Reaktors, von dem Größen gemessen werden, welche mit der Anordnung gemäß einem ersten Ausführungsbeispiel weiterverarbeitet werden;

Figur 2 eine Skizze einer Anordnung gemäß dem ersten Ausführungsbeispiel;

Figur 3 eine Skizze, welche einen Verfahrensablauf gemäß dem ersten oder zweiten Ausführungsbeispiel beschreibt;

Figur 4 eine Skizze einer Anordnung gemäß dem ersten Ausführungsbeispiel;

Figur 5 eine Skizze einer Anordnung gemäß einem zweiten Ausführungsbeispiel;

Figur 6 eine Skizze einer Anordnung bei einem Training gemäß dem zweiten Ausführungsbeispiel;

Figur 7 eine Skizze einer allgemeinen Beschreibung eines dynamischen Systems.

Erstes Ausführungsbeispiel: Chemischer Reaktor

Fig.1 zeigt einen chemischen Reaktor 100, der mit einer chemischen Substanz 101, welche ein Gemisch mehrerer Grundsubstanzen 103 ist, gefüllt ist. Der chemische Reaktor 100 umfaßt einen Rührer 102, mit dem die chemische Substanz 101 gerührt wird.

Durch eine Einspritzvorrichtung 150 werden die Grundsubstanzen 103 getrennt voneinander in den Reaktor 100 eingespritzt.

Die in den chemischen Reaktor 100 eingespritzten Grundsubstanzen 103 reagieren während eines vorgebbaren Zeitraums in dem chemischen Reaktor 100 miteinander, wobei die chemische Substanz 101 gebildet wird. Eine aus dem Reaktor 100 ausfließende Substanz 104 wird aus dem chemischen Reaktor 100 über einen Ausgang abgeleitet.

Die Einspritzvorrichtung 150 ist über eine Leitung mit einer Steuereinheit 105 verbunden, mit der über ein Steuersignal 106 ein überwachtes Einspritzen einer beliebigen Grundsubstanz 103 in den Reaktor 100 einstellbar ist.

Ferner ist ein Meßgerät 107 vorgesehen, mit dem Konzentrationen von den in der chemischen Substanz 101 enthaltenen Grundsubstanzen 103 und eine Temperatur in dem Reaktor 100 sowie ein in dem Reaktor 100 herrschender Druck gemessen werden.

Meßsignale 108 werden einem Rechner 109 zugeführt, in dem Rechner 109 über eine Eingangs-/Ausgangsschnittstelle 110 und einem Analog/Digital-Wandler 111 digitalisiert und in einem Speicher 112 gespeichert. Ein Prozessor 113 ist ebenso wie der Speicher 112 über einen Bus 114 mit dem Analog/Digital-Wandler 111 verbunden. Der Rechner 109 ist ferner über die Eingangs-/Ausgangsschnittstelle 110 mit der Steuerung 105 der Einspritzvorrichtung 150 verbunden und somit steuert der Rechner 109 das Einspritzen der Grundsubstanzen 103 in den Reaktor 100.

Der Rechner 109 ist ferner über die Eingangs-/Ausgangsschnittstelle 110 mit einer Tastatur 115, einer Computermaus 116 sowie einem Bildschirm 117 verbunden.

Der chemische Reaktor 100 als dynamisches technisches System 200 unterliegt somit einem dynamischen Prozeß.

Der chemische Reaktor 100 wird mittels einer Zustandsbeschreibung beschrieben. Die Eingangsgröße u_t setzt sich in

diesem Fall zusammen aus einer Angabe über die Temperatur, die in dem chemischen Reaktor 100 herrscht sowie dem in dem chemischen Reaktor 100 herrschenden Druck und der zu dem Zeitpunkt t eingestellten Röhrfrequenz. Somit ist die Ein-
gangsgröße u_t ein dreidimensionaler Vektor.

Ziel der im weiteren beschriebenen Modellierung des chemischen Reaktors 100 ist die Bestimmung der dynamischen Entwicklung der Konzentrationen der Grundsubstanzen 103 in dem Reaktor 100, um somit eine effiziente Erzeugung eines zu produzierenden vorgebbaren Zielstoffes als ausfließende Substanz 104 zu ermöglichen.

Eine effiziente Erzeugung des zu produzierenden vorgebbaren Zielstoffes ist dann möglich, wenn die Grundsubstanzen 103 in einem der durchzuführenden Reaktion entsprechenden Verhältnis der Konzentrationen der Grundsubstanzen 103 gemischt werden.

Die Bestimmung der dynamischen Entwicklung der Konzentrationen der Grundsubstanzen 103 erfolgt unter Verwendung der im weiteren beschriebenen und in Fig.3 dargestellten Anordnung.

Zum einfacheren Verständnis der der Anordnung zugrunde liegenden Prinzipien ist in Fig.2 eine Grundstruktur 200 als ein zweiteiliges neuronales Netz, bei welchem ein erstes 201 und ein zweites neuronales Netz 202 hintereinander geschaltet sind, dargestellt.

Die im weiteren beschriebenen Anordnungen sind jeweils so zu verstehen, daß jede Neuronenschicht bzw. jede Teilschicht eine vorgebbare Anzahl von Neuronen, d.h. Rechenelementen, aufweist.

Bei der in Fig.2 dargestellten Grundstruktur sind das erste neuronale Netz 201 und das zweite neuronale Netz 202 derart miteinander verknüpft, daß Ausgänge des ersten neuronalen

Netzes 201 mit Eingängen des zweiten neuronalen Netzes 202 verbunden sind.

Das erste neuronale Netz 201 weist eine erste Eingangsschicht 5 210 mit einer vorgebbaren Anzahl von Eingangs-Rechenelementen, d.h. Eingangsneuronen, auf, denen Eingangsgrößen u_t zu einem vorgebbaren Zeitpunkt t , d.h. im weiteren beschriebene Zeitreihenwerte, zuführbar sind.

10 Des Weiteren weist das erste neuronale Netz 210 Ausgangs-Rechenelemente, d.h. Ausgangsneuronen, einer ersten Ausgangsschicht 220 auf. Die Ausgangsneuronen der ersten Ausgangsschicht 220 sind mit den Eingangsneuronen der ersten Eingangsschicht 210 verbunden. Die Gewichte der Verbindungen 15 sind in einer ersten Verbindungsmatrix A enthalten.

Das zweite neuronale Netz 202 ist derart mit dem ersten neuronalen Netz 201 verbunden, daß die Ausgangsneuronen der ersten Ausgangsschicht 220 mit Eingangsneuronen einer zweiten 20 Eingangsschicht 230 gemäß einer durch eine zweite Verbindungsmatrix B gegebenen Struktur verbunden sind.

Bei dem zweiten neuronalen Netz 202 sind Ausgangsneuronen einer zweiten Ausgangsschicht 240 mit den Eingangsneuronen der 25 zweiten Eingangsschicht 230 verbunden. Gewichte der Verbindungen sind in einer dritten Verbindungsmatrix C enthalten.

An den Ausgangsneuronen der zweiten Ausgangsschicht 240 sind die Ausgangsgrößen y_t für jeweils einen Zeitpunkt t abgreifbar.

Aufbauend auf diese Grundstruktur wird im weiteren die in Fig.4 dargestellte erweiterte Anordnung gebildet erläutert.

35 Fig.4 zeigt ein drittes neuronales Netz 403, welches mit dem ersten neuronalen Netz 401 verknüpft ist.

Das dritte neuronale Netz 403 umfaßt eine dritte Eingangsschicht 450 mit Eingangsneuronen, welche mit Neuronen einer versteckten Schicht 460 gemäß der durch die erste Verbindungsmatrix A gegebenen Struktur verbunden sind.

5

Das dritte neuronale Netz 403 ist derart mit dem ersten neuronalen Netz 401 verbunden, daß die Neuronen der versteckten Schicht 460 mit den Ausgangsneuronen der ersten Ausgangsschicht 420 verbunden sind. Gewichte der Verbindungen sind in 10 einer vierten Verbindungsmatrix D enthalten.

Die Eingangsneuronen der dritten Eingangsschicht 450 sind derart ausgestaltet, daß ihnen die Zeitreihenwerte u_t zu einem vorgebbaren Zeitpunkt $t-1$ als Eingangsgrößen u_{t-1} zuführbar sind.

15 Durch die beschriebene Ausgestaltung des ersten neuronalen Netzes 401 und des dritten neuronalen Netzes 403 gemäß Fig.4 ist das Prinzip der sogenannten geteilten Gewichtswerte (Shared Weights), d.h. dem Grundsatz, daß äquivalente Verbindungsmatrizen in einem neuronalen Netz zu einem jeweiligen Zeitpunkt die gleichen Werte aufweisen, realisiert.

Bei der Anordnung gemäß Fig.4 wird insbesondere durch die geteilten Gewichtswerte sowie durch die beschriebene Ausgestaltung der ersten 410 und der dritten 450 Eingangsschicht erreicht, daß Zustände s_{t-1} und s_t , welche durch die erste Ausgangsschicht 420 und die versteckte Schicht 460 repräsentiert werden, zwei zeitlich aufeinanderfolgende Zustände $t-1$ und t 30 eines Systems s beschreiben.

Als Trainingsverfahren wird das Backpropagation-Verfahren eingesetzt. Der Trainingsdatensatz wird auf folgende Weise aus dem chemischen Reaktor 400 gewonnen.

35

Es werden mit dem Meßgerät 407 zu vorgegebenen Eingangsgrößen die Konzentrationen der Grundsubstanzen 103 gemessen und dem

Rechner 409 zugeführt, dort digitalisiert und als Zeitreihenwerte u_t in einem Speicher gemeinsam mit den entsprechenden Eingangsgrößen, die zu den gemessenen Größen korrespondieren, zeitlich aufeinanderfolgend gruppiert.

5

Bei einem Training der Anordnung werden diese Zeitreihenwerte u_t der Anordnung als Trainingsdatensatz zusammen mit der Angabe über das vorgegebene optimale Verhältnis der Konzentrationen der Grundsubstanzen zugeführt.

10

Die Anordnung aus Fig. 4 wird unter Verwendung des Trainingsdatensatzes trainiert.

15 Zur besseren Veranschaulichung der durch die Anordnung erreichten Transformationen sind in Fig. 3 Schritte eines Verfahrensablaufs 300 mit Bezug auf das erste Ausführungsbeispiel dargestellt.

20 In einem ersten Schritt 310 werden der Anordnung die Zeitreihenwerte der Eingangsgröße u_t , welche die Angaben über die Temperatur, den Druck und die Rührfrequenz in dem Reaktor 100 enthalten, zugeführt.

25 In einem zweiten Schritt 320 wird unter Verwendung der Eingangsgröße u_t eine Ausgangsgröße s_t des ersten neuronalen Netzes ermittelt, welche beschreibt, ob die Grundsubstanzen in dem für eine effektive Reaktion der Grundsubstanzen optimierten Verhältnis miteinander, welches einen sogenannten Gleichgewichtszustand in dem Reaktor darstellt, gemischt werden. Somit wird in dem zweiten Schritt 320 ermittelt, ob sich ein Zustand in dem Reaktor in einem Gleichgewichts- oder Ungleichgewichtszustand befindet.

35 In einem dritten Schritt 330 wird die Ausgangsgröße s_t des ersten neuronalen Netzes als Eingangsgröße dem zweiten neuronalen Netz zugeführt.

In einem vierten Schritt 340 ermittelt das zweite neuronale Netz die Ausgangsgröße y_t , welche eine dynamische Veränderung der Konzentrationen der Grundsubstanzen beschreibt.

5 In dem vierten Schritt 340 wird unter Verwendung der ermittelten Veränderung der Konzentrationen der Grundsubstanzen ein Zustand in dem Reaktor bestimmt, mit welchem der Ungleichgewichtszustand kompensiert werden kann.

10

Die gemäß dem oben beschriebenen Trainingsverfahren trainierte Anordnung aus Fig.4 wird zur Steuerung und Regelung des Einspritzvorgangs der Grundsubstanzen 103 in den chemischen Reaktor 100 eingesetzt.

15

Ziel der Regelung und der Steuerung ist ein automatisiertes, kontinuierliches Einspritzen der Grundsubstanzen 103 in den chemischen Reaktor 100 derart, daß das Konzentrationsverhältnis der Grundsubstanzen 103 in dem Reaktor 100 ein konstanter, für die durchzuführenden Reaktion optimales Verhältnis aufweist. Damit ist eine effiziente Erzeugung des zu produzierenden vorgebbaren Zielstoffes als ausfließende Substanz 104 möglich.

20

Dazu wird für eine erste Eingangsgröße u_{t-1} zu einem Zeitpunkt $t-1$ und eine zweite Eingangsgröße u_t zu einem Zeitpunkt t eine Prognosegröße y_t in einer Anwendungsphase von der Anordnung ermittelt, die anschließend als Steuergröße 420 nach einer eventuellen Aufbereitung der ermittelten Größe der Einspritzvorrichtung 150 zur Steuerung des Einspritzens der Grundsubstanzen 103 in dem chemischen Reaktor 100 zugeführt wird (vgl. Fig.1).

30 Durch die Strukturierung der Anordnung in das erste neuronale Netz und das zweite neuronale Netz, insbesondere durch eine durch diese Strukturierung gebildete weitere Fehlersignale produzierende Ausgangsschicht, wird erreicht, daß für ein

Training der Anordnung eine geringe Anzahl von Trainingsdaten notwendig ist, um eine hinreichender Genauigkeit bei der Modellierung des dynamischen Systems zu gewährleisten.

5

2. Ausführungsbeispiel: Wechselkursprognose

In einem zweiten Ausführungsbeispiels wird die oben beschriebene Anordnung gemäß Fig.4 für eine Wechselkursprognose eines 10 \$-DM Wechselkurses eingesetzt.

Als Eingangsgröße u_t wird eine Zeitreihe mit Zeitreihenwerten, welche jeweils Angaben über ökonomische Kennzahlen, beispielsweise Zinssätze von kurzfristigen und langfristigen 15 Zinsen in einem \$-Raum und einem DM-Raum, Inflationsraten und Angaben über ein Wirtschaftswachstum in dem \$-Raum und dem DM-Raum, umfassen, der Anordnung zugeführt.

Als Ausgangsgröße y_t wird von der Anordnung eine Veränderung 20 des \$-DM Wechselkurses prognostiziert.

Bei der Anordnung für die Wechselkursprognose weisen insbesondere die Verbindungsmatrizen A, B, C und D eine besondere Ausgestaltung auf.

25

Die erste Verbindungsmatrix A ist derart mit Gewichten besetzt, daß jeweils einem Neuron der ersten Ausgangsschicht nur eine begrenzte Anzahl von Neuronen der ersten Eingangsschicht des ersten neuronalen Netzes (in diesem Fall: maximal 30 sieben Neuronen) zugeordnet sind. Eine solche Verbindungsma- trix wird als "sparse connector" bezeichnet.

Ferner ist die Anordnung für die Wechselkursprognose derart ausgestaltet, daß die erste Ausgangsschicht des ersten neuronalen Netzes eine große Anzahl von Ausgangsneuronen aufweist 35 (in diesem Fall: 200 Ausgangsneuronen).

Die zweite Verbindungsma^{trix} B, in diesem Fall ein hochdimensionaler Vektor, ist derart ausgestaltet, daß unter Verwendung der Verbindungsma^{trix} B die hochdimensionale Ausgangsgröße s_t des ersten neuronalen Netzes (Dimension = 200) auf 5 eine eindimensionale Größe abgebildet wird. Insbesondere weisen alle Gewichte der zweiten Verbindungsma^{trix} B den Wert 1 auf.

10 Dementsprechend weist die dritte Verbindungsma^{trix} C nur einen Gewichtswert, welcher zusätzlich nur positive Werte annehmen kann, auf.

15 Die vierte Verbindungsma^{trix} D ist als eine Diagonalmatrix ausgestalten, bei der alle Diagonalwerte den Wert 1 aufweisen.

20 Als Trainingsverfahren wird ebenfalls das Backpropagation-Verfahren eingesetzt. Ein Trainingsdatensatz wird auf folgende Weise gebildet.

Es werden bekannte Wechselkursveränderungen als Zeitreihenwerte u_t gemeinsam mit den entsprechenden ökonomischen Kennzahlen, die zu den bekannten Wechselkursveränderungen korrespondieren, zeitlich aufeinanderfolgend gruppiert.

Bei einem Training der Anordnung werden diese Zeitreihenwerte u_t der Anordnung als Trainingsdatensatz zugeführt.

30 Bei dem Training weist eine Zielfunktion E, welche in der ersten Ausgangsschicht des ersten neuronalen Netzes gebildet wird, folgende Vorschrift auf:

$$E = \frac{1}{T} \sum_t \ln \left(\frac{p_t+1}{p_t} \right) * z_t^a \rightarrow \max \quad (5)$$

mit:

35 t : Index, welcher einen Zeitpunkt beschreibt
T : betrachtetes Zeitintervall

a : Index für ein Neuron
 ln(...) : natürlicher Logarithmus
 P_t, P_{t+1} : Wechselkurs zum Zeitpunkt t bzw. t+1
 z_t^a : eine einem Neuron a zugeordnete gewechselte Geldmenge in DM.

5 Ferner gelten folgende, ein dynamisches Wechselkurssystem beschreibende Beziehungen:

$$m_{t+1}^a = m_t^a - z_t^a \text{ (Marktmechanik des Wechselkurssystems)} \quad (6)$$

$$10 \quad n_{t+1}^a = n_t^a - P_t * z_t^a \text{ (Marktmechanik des Wechselkurssystems)} \quad (7)$$

$$\sum_a z_t^a = 0 \text{ (Gleichgewichtsbedingung des Wechselkurssystems)} \quad (8)$$

mit:

m_{t+1}^a, m_t^a : eine einem Neuron a zugeordnete Geldmenge in \$ zu einem Zeitpunkt t+1 bzw. t

15 n_{t+1}^a, n_t^a : eine einem Neuron a zugeordnete Geldmenge in DM zu einem Zeitpunkt t+1 bzw. t.

Der Anordnung für die Wechselkursprognose liegen folgende Prinzipien zugrunde:

20

Ein durch einen Überschuß einer Geldmenge verursachter Ungleichgewichtszustand des Wechselkurssystems wird durch eine Veränderung des Wechselkurses kompensiert.

25 Ein Zustand des Wechselkurssystems wird durch ein Entscheidungsmodell, welches in dem ersten neuronalen Netz realisiert ist, beschrieben. In diesem Fall repräsentiert jeweils ein Neuron einen sogenannten "Agenten". Dementsprechend wird die Anordnung für die Wechselkursprognose auch als "Multi-Agent-30 System" bezeichnet.

In dem zweiten neuronalen Netz ist ein Marktmodell realisiert, mit welchem ein Ungleichgewichtszustand, welcher durch das Entscheidungsmodell erzeugt wird, durch eine Verän-

derung eines Zustands eines Wechselkursmarktes kompensiert wird.

Ein Ungleichgewichtszustand des Entscheidungsmodells ist eine

5 Ursache für eine Zustandsänderung des Markmodells.

Im folgenden wird eine Alternative des zweiten Ausführungsbeispiels beschrieben.

10 Das alternative Ausführungsbeispiel unterscheidet sich von dem zweiten Ausführungsbeispiel in den nachfolgend beschriebenen Punkten. Die entsprechende Anordnung des alternativen Ausführungsbeispiels für die Wechselkursprognose ist jeweils in Fig.5 (Anwendungsphase) und Fig.6 (Trainingsphase) dargestellt.

15 Neuronenverbindungen, welche unterbrochen sind, sind in den Figuren gestrichelt gezeichnet. Geschlossene Neuronenverbindungen sind durch durchgezogene Linien dargestellt.

20 Die ursprüngliche Anordnung für die Wechselkursprognose gemäß Fig.4 kann dahingehend geändert werden, daß anstelle des dritten neuronalen Netzes eine vierte Eingangsschicht 550 mit Eingangsneuronen verwendet wird, welche mit den Ausgangsneuronen der zweiten Ausgangsschicht 540 des zweiten neuronalen Netzes verbunden sind. Gewichte der Verbindungen sind in einer fünften Verbindungsmatrix E enthalten. Die Verbindungen sind derart realisiert, daß sie in einer Anwendungsphase unterbrochen und in einer Trainingsphase geschlossen sind.

25 Ferner weist die zweite Ausgangsschicht 540 des zweiten neuronalen Netzes eine Rückführung auf, mit der die Ausgangssignale der zweiten Ausgangsschicht 540 in die zweite Ausgangsschicht 540 zurückgeführt werden. Gewichte der Rückführung sind in einer sechsten Verbindungsmatrix F enthalten.

30 Die Rückführung ist derart realisiert, daß sie in der Anwen-

dungsphase geschlossen und in der Trainingsphase unterbrochen ist.

5 Darüber hinaus sind die Ausgangsneuronen der ersten Ausgangsschicht 520 des ersten neuronalen Netzes mit den Ausgangsneuronen 540 des zweiten neuronalen Netzes verbunden. Gewichte der Verbindungen sind in einer siebten Verbindungsma

trix G enthalten.

10 Die Verbindungen zwischen der zweiten Eingangsschicht 530 und der zweiten Ausgangsschicht 540 sind derart ausgestaltet, daß sie in einer Anwendungsphase geschlossen und in einer Trainingsphase unterbrochen sind.

15 Die fünfte Verbindungsma

trix E und die sechste Verbindungsma

trix F ist jeweils eine Identitätsma

trix Id.

20 Die siebte Verbindungsma

trix G ist derart ausgestaltet, daß eine unter Verwendung der siebten Verbindungsma

trix G durchgef

ührte Abbildung folgender Vorschrift gehorcht:

$$\frac{d}{d(\ln(\frac{p_t+1}{p_t}))} \left(\sum_a z_t^a \right) < 0 \quad (9)$$

mit :

$$\frac{d}{d(\ln(\frac{p_t+1}{p_t}))} (\dots) : \text{Ableitung nach } \ln(\frac{p_t+1}{p_t})$$

25

Ein Training der alternativen Anordnung wird entsprechend dem zweiten Ausführungsbeispiels durchgef

ührte. Die alternative Trainingsanordnung ist in Fig.6 dargestellt.

30 Bei dem Training werden die Rückf

ührung und die Verbindungen zwischen der zweiten Eingangsschicht 530 und der zweiten Ausgangsschicht 540 unterbrochen.

5 In der Anwendungsphase kann eine Veränderung eines Wechselkurses, mit welcher ein Ungleichgewichtszustand des Marktes kompensiert werden kann, nach einem iterativen Prozeß an der zweiten Ausgangsschicht des zweiten neuronalen Netzes abgegriffen werden.

Im Rahmen des iterativen Prozesses wird folgendes Fixpunktproblem gelöst:

10 $\ln\left(\frac{P_t+1}{P_t}\right)_{n+1} = \left(\ln\left(\frac{P_t+1}{P_t}\right)_n + \varepsilon * \left(\sum_a z_t^a \left(\ln\left(\frac{P_t+1}{P_t}\right)_n\right)\right)\right)$ (10)

$\ln\left(\frac{P_t+1}{P_t}\right)_n \rightarrow$ Fixpunkt

mit:

15 ε : Gewicht der dritten Verbindungsmatrix C, $\varepsilon > 0$.
N : Index für einen Iterationsschritt

Der alternativen Anordnung für die Wechselkursprognose liegen folgende Prinzipien zugrunde:

20 Das Wechselkurssystem befindet sich zu jedem Zeitpunkt t in einem Gleichgewicht.

25 Durch eine Veränderung eines Zustands des Marktmodells kann ein Ungleichgewichtszustand des Entscheidungsmodells verhindert werden.

30 Im weiteren sind eine mögliche Realisierungen des oben beschriebenen zweiten Ausführungsbeispiels und eine mögliche Realisierung der Alternative des zweiten Ausführungsbeispiels angegeben für das Programm SENN, Version 2.3. Die Realisierungen umfassen jeweils drei Abschnitte, die jeweils einen Programmcode enthalten, die zur Verarbeitung in SENN, Version 2.3 erforderlich sind.

Mögliche Realisierung des zweiten Ausführungsbeispiels:

1. Parameter-Datei:

Für die Anwendungsphase:

```

5      BpNet {
10     Globals {
15       WtPenalty {
20         sel NoPenalty
25         Weigend {
30           Lambda { 0.000000 }
35           AutoAdapt { T }
40           w0 { 1.000000 }
45           DeltaLambda { 0.000001 }
50           ReducFac { 0.900000 }
55           Gamma { 0.900000 }
60           DesiredError { 0.000000 }
65           }
70         WtDecay {
75           Lambda { 0.010000 }
80           AutoAdapt { F }
85           AdaptTime { 10 }
90           EpsObj { 0.001000 }
95           ObjSet { Training }
100          EpsilonFac { 1.000000 }
105          }
110         ExtWtDecay {
115           Lambda { 0.001000 }
120           AutoAdapt { F }
125           AdaptTime { 10 }
130           EpsObj { 0.001000 }
135           ObjSet { Training }
140           EpsilonFac { 1.000000 }
145           }
150         Finnoff {
155           AutoAdapt { T }
160           Lambda { 0.000000 }
165           DeltaLambda { 0.000001 }
170           ReducFac { 0.900000 }
175           Gamma { 0.900000 }
180           DesiredError { 0.000000 }
185           }
190         }
195       ErrorFunc {
200         sel LnCosh
205         |x| {
210           parameter { 0.050000 }
215         }
220         LnCosh {
225           parameter { 2.000000 }
230         }
235       }
240       AnySave {
245         file_name { f.Globals.dat }
250       }
255       AnyLoad {
260         file_name { f.Globals.dat }
265       }
270       ASCII { F }
275     }
280     LearnCtrl {
285       sel Stochastic
290       Stochastic {
295         PatternSelection {
300           sel Permute
305           SubSample {
310             Percent { 0.500000 }
315           }
320           ExpRandom {
325         }
330       }
335     }
340   }
345 
```

```

        Lambda { 2.000000 }
    }
}
5   WtPruneCtrl {
    PruneSchedule {
        sel FixSchedule
        FixSchedule {
            Limit_0 { 10 }
            Limit_1 { 10 }
            Limit_2 { 10 }
            Limit_3 { 10 }
            RepeatLast { T }
        }
        10  DynSchedule {
            MaxLength { 4 }
            MinimumRuns { 0 }
            Training { F }
            Validation { T }
            Generalization { F }
        }
        15  DivSchedule {
            Divergence { 0.100000 }
            MinEpochs { 5 }
        }
    }
    20  PruneAlg {
        sel FixPrune
        FixPrune {
            Perc_0 { 0.100000 }
            Perc_1 { 0.100000 }
            Perc_2 { 0.100000 }
            Perc_3 { 0.100000 }
        }
        25  EpsiPrune {
            DeltaEps { 0.050000 }
            StartEps { 0.050000 }
            MaxEps { 1.000000 }
            ReuseEps { F }
        }
        30  Tracer {
            Active { F }
            Set { Validation }
            File { trace }
        }
        35  Active { F }
            Randomize { 0.000000 }
            PruningSet { Train.+Valid. }
            Method { S-Pruning }
        }
        40  StopControl {
            EpochLimit {
                Active { F }
                MaxEpoch { 60 }
            }
            45  MovingExpAverage {
                Active { F }
                MaxLength { 4 }
                Training { F }
                Validation { T }
                Generalization { F }
                Decay { 0.900000 }
            }
            50  CheckObjectiveFct {
                Active { F }
                MaxLength { 4 }
                Training { F }
                Validation { T }
                Generalization { F }
            }
            55  CheckDelta {
                Active { F }
                Divergence { 0.100000 }
            }
            60  EtaCtrl {
                Mode {
                    sel EtaSchedule

```

```

        EtaSchedule {
            SwitchTime { 10 }
            ReductFactor { 0.950000 }
        }
5        FuzzCtrl {
            MaxDeltaObj { 0.300000 }
            MaxDelta2Obj { 0.300000 }
            MaxEtaChange { 0.020000 }
            MinEta { 0.001000 }
            MaxEta { 0.100000 }
            Smoother { 1.000000 }
        }
        Active { F }
15       LearnAlgo {
            sel OnlineBackProp
            VarioEta {
                MinCalls { 50 }
            }
            MomentumBackProp {
                Alpha { 0.050000 }
            }
            Quickprop {
                Decay { 0.050000 }
                Mu { 2.000000 }
            }
        }
30       AnySave {
            file_name { f.Stochastic.dat }
        }
        AnyLoad {
            file_name { f.Stochastic.dat }
        }
35       BatchSize { 1 }
        Eta { 0.001000 }
        DerivEps { 0.000000 }
    }
40       TrueBatch {
            PatternSelection {
                sel Sequential
                SubSample {
                    Percent { 0.500000 }
                }
                ExpRandom {
                    Lambda { 2.000000 }
                }
            }
            WtPruneCtrl {
                Tracer {
                    Active { F }
                    Set { Validation }
                    File { trace }
                }
                Active { F }
                Randomize { 0.000000 }
                PruningSet { Train.+Valid. }
                Method { S-Pruning }
            }
        }
50       EtaCtrl {
            Active { F }
        }
        LearnAlgo {
            sel VarioEta
            VarioEta {
                MinCalls { 200 }
            }
            MomentumBackProp {
                Alpha { 0.050000 }
            }
            Quickprop {
                Decay { 0.050000 }
                Mu { 2.000000 }
            }
        }
60       AnySave {
            file_name { f.TrueBatch.dat }
        }

```

```

      AnyLoad {
        file_name { f.TrueBatch.dat }
      }
      Eta { 0.050000 }
      DerivEps { 0.000000 }
    5
  }
  LineSearch {
    PatternSelection {
      sel Sequential
    }
    SubSample {
      Percent { 0.500000 }
    }
    ExpRandom {
      Lambda { 2.000000 }
    }
  10
  }
  WtPruneCtrl {
    Tracer {
      Active { F }
      Set { Validation }
      File { trace }
    }
    Active { F }
    Randomize { 0.000000 }
    PruningSet { Train.+Valid. }
    Method { S-Pruning }
  15
  }
  LearnAlgo {
    sel ConjGradient
    VarioEta {
      MinCalls { 200 }
    }
    MomentumBackProp {
      Alpha { 0.050000 }
    }
  20
    Quickprop {
      Decay { 0.050000 }
      Mu { 2.000000 }
    }
  25
    Low-Memory-BFGS {
      Limit { 2 }
    }
  30
  }
  AnySave {
    file_name { f.LineSearch.dat }
  }
  AnyLoad {
    file_name { f.LineSearch.dat }
  }
  35
    EtaNull { 1.000000 }
    MaxSteps { 10 }
    LS_Precision { 0.500000 }
    TrustRegion { T }
    DerivEps { 0.000000 }
    BatchSize { 2147483647 }
  40
  }
  GeneticWeightSelect {
    PatternSelection {
      sel Sequential
      SubSample {
        Percent { 0.500000 }
      }
      ExpRandom {
        Lambda { 2.000000 }
      }
    }
  45
    LearnAlgo {
      sel VarioEta
      VarioEta {
        MinCalls { 200 }
      }
      MomentumBackProp {
        Alpha { 0.050000 }
      }
    }
  50
  }
  55
  ObjFctTracer {
    Active { F }
    File { objFunc }
  }

```

```

        }
    SearchControl {
        SearchStrategy {
            sel HillClimberControl
            HillClimberControl {
                &InitialAlive { 0.950000 }
                InheritWeights { T }
                Beta { 0.100000 }
                MutationType { DistributedMacroMutation }
                MaxTrials { 50 }
            }
            PBILControl {
                &InitialAlive { 0.950000 }
                InheritWeights { T }
                Beta { 0.100000 }
                Alpha { 0.100000 }
                PopulationSize { 40 }
            }
        }
        PopulationControl {
            pCrossover { 1.000000 }
            CrossoverType { SimpleCrossover }
            Scaling { T }
            ScalingFactor { 2.000000 }
            Sharing { T }
            SharingFactor { 0.050000 }
            PopulationSize { 50 }
            min.&InitialAlive { 0.010000 }
            max.&InitialAlive { 0.100000 }
        }
        pMutation { 0.000000 }
    }
    ObjectiveFunctionWeights {
        &Alive { 0.600000 }
        E(TS) { 0.200000 }
        Improvement(TS) { 0.000000 }
        E(VS) { 1.000000 }
        Improvement(VS) { 0.000000 }
        (E(TS)-E(VS))/max(E(TS),E(VS)) { 0.000000 }
        LipComplexity { 0.000000 }
        OptComplexity { 2.000000 }
        testVal(dead)-testVal(alive) { 0.000000 }
    }
    AnySave {
        file_name { f.GeneticWeightSelect.dat }
    }
    AnyLoad {
        file_name { f.GeneticWeightSelect.dat }
    }
    Eta { 0.050000 }
    DerivEps { 0.000000 }
    BatchSize { 5 }
    #minEpochsForFitnessTest { 2 }
    #maxEpochsForFitnessTest { 3 }
    SelectWeights { T }
    SelectNodes { T }
    maxGrowthOfValError { 0.005000 }
}
CCMenu {
    Clusters {
        mlp.input {
            ActFunction {
                sel id
                plogistic {
                    parameter { 0.500000 }
                }
                ptanh {
                    parameter { 0.500000 }
                }
                pid {
                    parameter { 0.500000 }
                }
            }
        }
        InputModification {
            sel None
            AdaptiveUniformNoise {
                NoiseEta { 1.000000 }
            }
        }
    }
}

```

```

        DampingFactor { 1.000000 }
    }
    AdaptiveGaussNoise {
        NoiseEta { 1.000000 }
        DampingFactor { 1.000000 }
    }
    FixedUniformNoise {
        SetNoiseLevel {
            NewNoiseLevel { 1.045229 }
        }
    }
    FixedGaussNoise {
        SetNoiseLevel {
            NewNoiseLevel { 1.045229 }
        }
    }
}
SaveNoiseLevel {
    Filename { noise_level.dat }
}
LoadNoiseLevel {
    Filename { noise_level.dat }
}
SaveManipulatorData {
    Filename { inputManip.dat }
}
LoadManipulatorData {
    Filename { inputManip.dat }
}
Norm { NoNorm }
}
mlp.excessDemand {
    ActFunction {
        sel id
        plogistic {
            parameter { 0.500000 }
        }
        ptanh {
            parameter { 0.500000 }
        }
        pid {
            parameter { 0.500000 }
        }
    }
}
mlp.price {
    ActFunction {
        sel id
        plogistic {
            parameter { 0.500000 }
        }
        ptanh {
            parameter { 0.500000 }
        }
        pid {
            parameter { 0.500000 }
        }
    }
}
ErrorFunc {
    sel LnCosh
    |x| {
        parameter { 0.050000 }
    }
    LnCosh {
        parameter { 2.000000 }
    }
}
ToleranceFlag { F }
Tolerance { 0.000000 }
Weighting { 2.000000 }
}
mlp.agents {
    ActFunction {
        sel tanh
        plogistic {
            parameter { 0.500000 }
        }
        ptanh {

```



```

      AllowPruning { F }
      EtaModifier { 1.000000 }
    }
  5   mlp.excessDemand->price {
      WeightWatcher {
        Active { T }
        MaxWeight { 2.000000 }
        MinWeight { 0.010000 }
      }
    10  LoadWeightsLocal {
        Filename { std }
      }
      SaveWeightsLocal {
        Filename { std }
      }
    15  Alive { T }
      WtFreeze { F }
      AllowGeneticOptimization { F }
      Penalty { NoPenalty }
    20  AllowPruning { F }
      EtaModifier { 1.000000 }
    }
    25  mlp.input->agents {
      WeightWatcher {
        Active { F }
        MaxWeight { 1.000000 }
        MinWeight { 0.000000 }
      }
    30  LoadWeightsLocal {
        Filename { std }
      }
      SaveWeightsLocal {
        Filename { std }
      }
    35  Alive { T }
      WtFreeze { F }
      AllowGeneticOptimization { F }
      Penalty { NoPenalty }
      AllowPruning { T }
      EtaModifier { 1.000000 }
    }
    40  mlp.bias->agents {
      WeightWatcher {
        Active { F }
        MaxWeight { 1.000000 }
        MinWeight { 0.000000 }
      }
    45  LoadWeightsLocal {
        Filename { std }
      }
      SaveWeightsLocal {
        Filename { std }
      }
    50  Alive { T }
      WtFreeze { F }
      AllowGeneticOptimization { F }
      Penalty { NoPenalty }
      AllowPruning { F }
      EtaModifier { 1.000000 }
    }
    55  AnySave {
      file_name { f.CCMMenu.dat }
    }
    60  AnyLoad {
      file_name { f.CCMMenu.dat }
    }
    65  TestRun {
      Filename { Test }
      Part.Transformed { F }
    }
    70  Online {
      Filename { Online.dat }
    }
    75  }
  
```

Für die Testphase:

```

BpNet {
  Globals {
    WtPenalty {
      sel NoPenalty
      Weigend {
        Lambda { 0.000000 }
        AutoAdapt { T }
        w0 { 1.000000 }
      }
      10 DeltaLambda { 0.000001 }
      ReducFac { 0.900000 }
      Gamma { 0.900000 }
      DesiredError { 0.000000 }
    }
    15 WtDecay {
      Lambda { 0.010000 }
      AutoAdapt { F }
      AdaptTime { 10 }
      EpsObj { 0.001000 }
    }
    20 ObjSet { Training }
      EpsilonFac { 1.000000 }
    }
    ExtWtDecay {
      Lambda { 0.001000 }
    }
    25 AutoAdapt { F }
      AdaptTime { 10 }
      EpsObj { 0.001000 }
      ObjSet { Training }
      EpsilonFac { 1.000000 }
    }
    30 Finnoff {
      AutoAdapt { T }
      Lambda { 0.000000 }
      DeltaLambda { 0.000001 }
    }
    35 ReducFac { 0.900000 }
      Gamma { 0.900000 }
      DesiredError { 0.000000 }
    }
    40 ErrorFunc {
      sel LnCosh
      |x| {
        parameter { 0.050000 }
      }
    }
    45 LnCosh {
      parameter { 2.000000 }
    }
    50 AnySave {
      file_name { f.Globals.dat }
    }
    AnyLoad {
      file_name { f.Globals.dat }
    }
    55 ASCII { T }
  }
  LearnCtrl {
    sel Stochastic
    Stochastic {
      PatternSelection {
        sel Permute
        SubSample {
          Percent { 0.500000 }
        }
      }
      65 ExpRandom {
        Lambda { 2.000000 }
      }
    }
    70 WtPruneCtrl {
      PruneSchedule {
        sel FixSchedule
        FixSchedule {
          Limit_0 { 10 }
        }
      }
    }
  }
}

```

```

      Limit_1 { 10 }
      Limit_2 { 10 }
      Limit_3 { 10 }
      RepeatLast { T }
  5
  }
  DynSchedule {
    MaxLength { 4 }
    MinimumRuns { 0 }
    Training { F }
    Validation { T }
    Generalization { F }
  10
  }
  DivSchedule {
    Divergence { 0.100000 }
  15
    MinEpochs { 5 }
  }
  }
  PruneAlg {
    sel FixPrune
  20
    FixPrune {
      Perc_0 { 0.100000 }
      Perc_1 { 0.100000 }
      Perc_2 { 0.100000 }
      Perc_3 { 0.100000 }
    }
    EpsiPrune {
      DeltaEps { 0.050000 }
      StartEps { 0.050000 }
      MaxEps { 1.000000 }
      ReuseEps { F }
    }
  30
  }
  }
  Tracer {
    Active { F }
  35
    Set { Validation }
    File { trace }
  }
  Active { F }
  Randomize { 0.000000 }
  40
  PruningSet { Train.+Valid. }
  Method { S-Pruning }
  }
  StopControl {
    EpochLimit {
      Active { F }
      MaxEpoch { 60 }
    }
  45
    MovingExpAverage {
      Active { F }
      MaxLength { 4 }
      Training { F }
      Validation { T }
      Generalization { F }
      Decay { 0.900000 }
    }
  50
    CheckObjectiveFct {
      Active { F }
      MaxLength { 4 }
      Training { F }
      Validation { T }
      Generalization { F }
    }
  55
    CheckDelta {
      Active { F }
      Divergence { 0.100000 }
    }
  60
  }
  EtaCtrl {
    Mode {
      sel EtaSchedule
      EtaSchedule {
        SwitchTime { 10 }
        ReductFactor { 0.950000 }
      }
  65
      FuzzCtrl {
        MaxDeltaObj { 0.300000 }
        MaxDelta2Obj { 0.300000 }
        MaxEtaChange { 0.020000 }
      }
    }
  70
  }
  75

```

```

        MinEta { 0.001000 }
        MaxEta { 0.100000 }
        Smoother { 1.000000 }
    5      }
    }
    Active { F }
}
LearnAlgo {
sel VarioEta
VarioEta {
    MinCalls { 50 }
}
MomentumBackProp {
    Alpha { 0.050000 }
}
10     }
Quickprop {
    Decay { 0.050000 }
    Mu { 2.000000 }
}
20     }
AnySave {
    file_name { f.Stochastic.dat }
}
AnyLoad {
    file_name { f.Stochastic.dat }
}
25     }
BatchSize { 10 }
Eta { 0.010000 }
DerivEps { 0.010000 }
30     }
TrueBatch {
    PatternSelection {
        sel Sequential
        SubSample {
            Percent { 0.500000 }
}
        ExpRandom {
            Lambda { 2.000000 }
}
    }
}
40     }
WtPruneCtrl {
    Tracer {
        Active { F }
        Set { Validation }
        File { trace }
}
    }
    Active { F }
    Randomize { 0.000000 }
    PruningSet { Train.+Valid. }
    Method { S-Pruning }
}
50     }
EtaCtrl {
    Active { F }
}
55     }
LearnAlgo {
sel VarioEta
VarioEta {
    MinCalls { 200 }
}
MomentumBackProp {
    Alpha { 0.050000 }
}
Quickprop {
    Decay { 0.050000 }
    Mu { 2.000000 }
}
60     }
}
65     }
AnySave {
    file_name { f.TrueBatch.dat }
}
AnyLoad {
    file_name { f.TrueBatch.dat }
}
70     }
Eta { 0.050000 }
DerivEps { 0.010000 }
}
75     }
LineSearch {
    PatternSelection {
}

```

```

      sel Sequential
      SubSample {
        Percent { 0.500000 }
      }
      ExpRandom {
        Lambda { 2.000000 }
      }
    }
    WtPruneCtrl {
      Tracer {
        Active { F }
        Set { Validation }
        File { trace }
      }
      Active { F }
      Randomize { 0.000000 }
      PruningSet { Train.+Valid. }
      Method { S-Pruning }
    }
    LearnAlgo {
      sel ConjGradient
      VarioEta {
        MinCalls { 200 }
      }
      MomentumBackProp {
        Alpha { 0.050000 }
      }
      Quickprop {
        Decay { 0.050000 }
        Mu { 2.000000 }
      }
      Low-Memory-BFGS {
        Limit { 2 }
      }
    }
    AnySave {
      file_name { f.LineSearch.dat }
    }
    AnyLoad {
      file_name { f.LineSearch.dat }
    }
    EtaNull { 1.000000 }
    MaxSteps { 10 }
    LS_Precision { 0.500000 }
    TrustRegion { T }
    DerivEps { 0.010000 }
    BatchSize { 2147483647 }
  }
  GeneticWeightSelect {
    PatternSelection {
      sel Sequential
      SubSample {
        Percent { 0.500000 }
      }
      ExpRandom {
        Lambda { 2.000000 }
      }
    }
    LearnAlgo {
      sel VarioEta
      VarioEta {
        MinCalls { 200 }
      }
      MomentumBackProp {
        Alpha { 0.050000 }
      }
    }
    ObjFctTracer {
      Active { F }
      File { objFunc }
    }
    SearchControl {
      SearchStrategy {
        sel HillClimberControl
        HillClimberControl {
          %InitialAlive { 0.950000 }
          InheritWeights { T }
          Beta { 0.100000 }
        }
      }
    }
  }
}

```

```

MutationType { DistributedMacroMutation }
MaxTrials { 50 }
}
5 PBILControl {
  %InitialAlive { 0.950000 }
  InheritWeights { T }
  Beta { 0.100000 }
  Alpha { 0.100000 }
  PopulationSize { 40 }
}
10 PopulationControl {
  pCrossover { 1.000000 }
  CrossoverType { SimpleCrossover }
}
15 Scaling { T }
  ScalingFactor { 2.000000 }
  Sharing { T }
  SharingFactor { 0.050000 }
  PopulationSize { 50 }
  min.%InitialAlive { 0.010000 }
20 max.%InitialAlive { 0.100000 }
}
}
pMutation { 0.000000 }
}
25 ObjectiveFunctionWeights {
  %Alive { 0.600000 }
  E(TS) { 0.200000 }
  Improvement(TS) { 0.000000 }
  E(VS) { 1.000000 }
}
30 Improvement(VS) { 0.000000 }
  (E(TS)-E(VS))/max(E(TS),E(VS)) { 0.000000 }
  LipComplexity { 0.000000 }
  OptComplexity { 2.000000 }
  testVal(dead)-testVal(alive) { 0.000000 }
}
35 AnySave {
  file_name { f.GeneticWeightSelect.dat }
}
40 AnyLoad {
  file_name { f.GeneticWeightSelect.dat }
}
Eta { 0.050000 }
DerivEps { 0.010000 }
45 BatchSize { 5 }
#minEpochsForFitnessTest { 2 }
#maxEpochsForFitnessTest { 3 }
SelectWeights { T }
SelectNodes { T }
50 maxGrowthOfValError { 0.005000 }
}
}
CCMenu {
  Clusters {
    mlp.inputP1 {
      ActFunction {
        sel id
        plogistic {
          parameter { 0.500000 }
        }
55        ptanh {
          parameter { 0.500000 }
        }
        pid {
          parameter { 0.500000 }
        }
      }
      InputModification {
        sel None
        AdaptiveUniformNoise {
          NoiseEta { 1.000000 }
          DampingFactor { 1.000000 }
        }
50        AdaptiveGaussNoise {
          NoiseEta { 1.000000 }
          DampingFactor { 1.000000 }
        }
        FixedUniformNoise {
          SetNoiseLevel {

```

```
        NewNoiseLevel { 0.000000 }
    }
}
5 FixedGaussNoise {
    SetNoiseLevel {
        NewNoiseLevel { 0.000000 }
    }
}
10 SaveNoiseLevel {
    Filename { noise_level.dat }
}
LoadNoiseLevel {
    Filename { noise_level.dat }
15 SaveManipulatorData {
    Filename { inputManip.dat }
}
LoadManipulatorData {
    Filename { inputManip.dat }
}
20 Norm { NoNorm }
}
25 mlp.input {
    ActFunction {
        sel id
        plogistic {
            parameter { 0.500000 }
        }
        ptanh {
            parameter { 0.500000 }
        }
        pid {
            parameter { 0.500000 }
        }
30 }
35 InputModification {
    sel None
    AdaptiveUniformNoise {
        NoiseEta { 1.000000 }
        DampingFactor { 1.000000 }
    }
40 AdaptiveGaussNoise {
    NoiseEta { 1.000000 }
    DampingFactor { 1.000000 }
}
45 FixedUniformNoise {
    SetNoiseLevel {
        NewNoiseLevel { 0.000000 }
    }
}
50 FixedGaussNoise {
    SetNoiseLevel {
        NewNoiseLevel { 0.000000 }
    }
}
55 }
60 SaveNoiseLevel {
    Filename { noise_level.dat }
}
LoadNoiseLevel {
    Filename { noise_level.dat }
}
65 SaveManipulatorData {
    Filename { inputManip.dat }
}
LoadManipulatorData {
    Filename { inputManip.dat }
}
70 Norm { NoNorm }
}
75 mlp.agentsP1 {
    ActFunction {
        sel id
        plogistic {
            parameter { 0.500000 }
        }
        ptanh {
```



```

    |x| {
        parameter { 0.050000 }
    }
    LnCosh {
        parameter { 2.000000 }
    }
}
ToleranceFlag { F }
Tolerance { 0.000000 }
Weighting { 1.000000 }
}
Connectors {
    mlp.inputP1->agentsP1 {
        WeightWatcher {
            Active { F }
            MaxWeight { 1.000000 }
            MinWeight { 0.000000 }
        }
        LoadWeightsLocal {
            Filename { std }
        }
        SaveWeightsLocal {
            Filename { std }
        }
        Alive { T }
        WtFreeze { F }
        AllowPruning { T }
        EtaModifier { 1.000000 }
        Penalty { NoPenalty }
    }
    mlp.bias->agentsP1 {
        WeightWatcher {
            Active { F }
            MaxWeight { 1.000000 }
            MinWeight { 0.000000 }
        }
        LoadWeightsLocal {
            Filename { std }
        }
        SaveWeightsLocal {
            Filename { std }
        }
        Alive { T }
        WtFreeze { F }
        AllowPruning { F }
        EtaModifier { 1.000000 }
        Penalty { NoPenalty }
    }
    mlp.input->agents {
        LoadWeightsLocal {
            Filename { std }
        }
        SaveWeightsLocal {
            Filename { std }
        }
        Alive { T }
        WtFreeze { F }
        AllowPruning { T }
        EtaModifier { 1.000000 }
        Penalty { NoPenalty }
    }
    mlp.bias->agents {
        LoadWeightsLocal {
            Filename { std }
        }
        SaveWeightsLocal {
            Filename { std }
        }
        Alive { T }
        WtFreeze { F }
        AllowPruning { F }
        EtaModifier { 1.000000 }
        Penalty { NoPenalty }
    }
    mlp.agentsP1->agents {
        WeightWatcher {
            Active { F }

```

```

        MaxWeight { 1.000000 }
        MinWeight { 0.000000 }
    }
5    LoadWeightsLocal {
        Filename { std }
    }
    SaveWeightsLocal {
        Filename { std }
    }
10   Alive { T }
    WtFreeze { F }
    AllowPruning { F }
    Penalty { NoPenalty }
    EtaModifier { 1.000000 }
15   }
    mlp.agents->excessDemand {
        WeightWatcher {
            Active { T }
            MaxWeight { 1.000000 }
20   MinWeight { 1.000000 }
    }
    LoadWeightsLocal {
        Filename { std }
    }
    SaveWeightsLocal {
        Filename { std }
    }
25   Alive { T }
    WtFreeze { T }
    AllowPruning { F }
    Penalty { NoPenalty }
    EtaModifier { 1.000000 }
30   }
    mlp.excessDemand->price {
        WeightWatcher {
            Active { T }
            MaxWeight { 2.000000 }
            MinWeight { 0.010000 }
        }
40   LoadWeightsLocal {
        Filename { std }
    }
    SaveWeightsLocal {
        Filename { std }
    }
45   Alive { T }
    WtFreeze { F }
    AllowPruning { F }
    Penalty { NoPenalty }
    EtaModifier { 1.000000 }
50   }
    AnySave {
        file_name { f.CCMenu.dat }
    }
    AnyLoad {
        file_name { f.CCMenu.dat }
    }
55   }
60   TestRun {
        Filename { Test }
        Part.Transformed { F }
    }
65   Online {
        Filename { Online.dat }
    }
}

```

2. Spezifikations-Datei:

APPLICATION Dollar_Prognose_Grimmdaten

70 MODE DAY WEEK 5

```

FROM 01.01.1991 TO MAX

TRAINING FROM 01.01.1991 TO 03.09.1996

5  VALIDATION FROM 03.09.1995 TO 03.09.1996
// VALIDATION RANDOM 0%

10 INPUT CLUSTER mlp.inputP1

    BEGIN DEMUSD "DMARKER/USDOLLR"
        x = FILE data/dol.txt COLUMN 1

15    INPUT = scale((x - x(-1)) / x(-1))
        LAG -1
        INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
        LAG -1
    END

20

    BEGIN JPYUSD "JAPAYEN/USDOLLR"
        x = FILE data/dol.txt COLUMN 2

25    INPUT = scale((x - x(-1)) / x(-1))
        LAG -1
        INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
        LAG -1
    END

30

    BEGIN ECUS3M "EURO-CURRENCY (LDN) US$ 3 MONTHS - MIDDLE RATE"
        x = FILE data/dol.txt COLUMN 3

35    INPUT = scale((x - x(-1)) / x(-1))
        LAG -1
        INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
        LAG -1
    END

40

    BEGIN ECWGM3M "EURO-CURRENCY (LDN) D-MARK 3 MONTHS - MIDDLE RATE"
        x = FILE data/dol.txt COLUMN 4

45    INPUT = scale((x - x(-1)) / x(-1))
        LAG -1
        INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
        LAG -1
    END

50

    BEGIN AUSVG4RY "US TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
        x = FILE data/dol.txt COLUMN 5

55    INPUT = scale((x - x(-1)) / x(-1))
        LAG -1
        INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
        LAG -1
    END

60

    BEGIN ABDGVG4RY "BD TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
        x = FILE data/dol.txt COLUMN 6

65    INPUT = scale((x - x(-1)) / x(-1))
        LAG -1
        INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
        LAG -1
    END

70

    BEGIN AJPGVG4RY "JP TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
        x = FILE data/dol.txt COLUMN 7

75    INPUT = scale((x - x(-1)) / x(-1))
        LAG -1
        INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
        LAG -1

```

```

END

5 BEGIN TOTMKUSRI "US-DS MARKET - TOT RETURN IND"
  x = FILE data/dol.txt COLUMN 8

  INPUT = scale((x - x(-1)) / x(-1))
  LAG -1
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
  LAG -1
10 END

15 BEGIN TOTMKBDRI "GERMANY-DS MARKET - TOT RETURN IND"
  x = FILE data/dol.txt COLUMN 9

  INPUT = scale((x - x(-1)) / x(-1))
  LAG -1
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
  LAG -1
20 END

25 BEGIN NYFECRB "COMMODITY RESEARCH BUREAU INDEX-CRB - PRICE INDEX"
  x = FILE data/dol.txt COLUMN 10

  INPUT = scale((x - x(-1)) / x(-1))
  LAG -1
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
  LAG -1
30 END

35 BEGIN GOLDBLN "GOLD BULLION $/TROY OUNCE"
  x = FILE data/dol.txt COLUMN 11

  INPUT = scale((x - x(-1)) / x(-1))
  LAG -1
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
  LAG -1
40 END

45 INPUT CLUSTER mlp.input

50 BEGIN DEMUSD "DMARKER/USDOLLR"
  x = FILE data/dol.txt COLUMN 1

  INPUT = scale((x - x(-1)) / x(-1))
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

55 BEGIN JPYUSD "JAPAYEN/USDOLLR"
  x = FILE data/dol.txt COLUMN 2

  INPUT = scale((x - x(-1)) / x(-1))
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

60 BEGIN ECUS3M "EURO-CURRENCY (LDN) US$ 3 MONTHS - MIDDLE RATE"
  x = FILE data/dol.txt COLUMN 3

  INPUT = scale((x - x(-1)) / x(-1))
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

65 BEGIN ECWGM3M "EURO-CURRENCY (LDN) D-MARK 3 MONTHS - MIDDLE RATE"
  x = FILE data/dol.txt COLUMN 4

  INPUT = scale((x - x(-1)) / x(-1))

```

```

      INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

5      BEGIN AUSGVG4RY "US TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
      x = FILE data/dol.txt COLUMN 5

10     INPUT = scale((x - x(-1)) / x(-1))
      INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

15     BEGIN ABDGVG4RY "BD TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
      x = FILE data/dol.txt COLUMN 6

      INPUT = scale((x - x(-1)) / x(-1))
20     INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

25     BEGIN AJPGVG4RY "JP TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
      x = FILE data/dol.txt COLUMN 7

      INPUT = scale((x - x(-1)) / x(-1))
      INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

35     BEGIN TOTMKUSRI "US-DS MARKET - TOT RETURN IND"
      x = FILE data/dol.txt COLUMN 8

      INPUT = scale((x - x(-1)) / x(-1))
      INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

40     BEGIN TOTMKBDRI "GERMANY-DS MARKET - TOT RETURN IND"
      x = FILE data/dol.txt COLUMN 9

      INPUT = scale((x - x(-1)) / x(-1))
      INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

50     BEGIN NYFECRB "COMMODITY RESEARCH BUREAU INDEX-CRB - PRICE INDEX"
      x = FILE data/dol.txt COLUMN 10

      INPUT = scale((x - x(-1)) / x(-1))
      INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

60     BEGIN GOLDBLN "GOLD BULLION $/TROY OUNCE"
      x = FILE data/dol.txt COLUMN 11

      INPUT = scale((x - x(-1)) / x(-1))
      INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

70     TARGET CLUSTER mlp.agentsP1

75     BEGIN agents behavior past 1
      x = FILE data/dol.txt COLUMN 1

      TARGET = 100 * ln(x / x(-1))
      TARGET = 100 * ln(x / x(-1))

```



```

SIGNAL

5      BEGIN hit rate = NORMSUM(signal)
          t = TARGET channel
          o = OUTPUT channel

          SIGNAL = IF t * o > 0 THEN 1 ELSE 0
      END

10

      BEGIN ROI
          y = FILE data/dol.txt COLUMN 1
          o = OUTPUT channel

          SIGNAL = (y(1) / y - 1) * sign(o)
      END

20

      BEGIN realized potential = Relsum(signal1, signal2)
          y = FILE data/dol.txt COLUMN 1
          o = OUTPUT channel

          SIGNAL = (y(1) / y - 1) * sign(o)
          SIGNAL = abs(y(1) / y - 1)
      END

25

30      BEGIN Backtransformation of forecasts
          y = FILE data/dol.txt COLUMN 1
          o = OUTPUT channel

          SIGNAL = y(1)

          SIGNAL = y * (1 + o / 100)
      END

35

40      BEGIN Buy & Hold
          y = FILE data/dol.txt COLUMN 1

          SIGNAL = y(1) / y - 1
      END

45

50      BEGIN Naiv Prognose
          y = FILE data/dol.txt COLUMN 1

          SIGNAL = (y(1) / y - 1) * sign(y - y(-1))
      END

```

3. Modell-Top-Datei:

```

net {
55      cluster INPUT ( EQUIVALENT, IN );
      cluster AGENTS ( EQUIVALENT, OUT );

      connect INPUT_AGENTS ( INPUT -> AGENTS, RANDOM(20));
      connect BIAS_AGENTS ( bias -> AGENTS );

60      INPUT inputP1;
      INPUT input;
      AGENTS agentsP1;
      AGENTS agents;

65      cluster ( DIM(1), HID) excessDemand;
      cluster (          OUT) price;

      connect ( inputP1      -> agentsP1, INPUT_AGENTS );
      connect ( bias         -> agentsP1, BIAS_AGENTS );
      connect ( input         -> agents , INPUT_AGENTS );
      connect ( bias         -> agents , BIAS_AGENTS );
      connect ( agentsP1     -> agents , DIAGONAL(1.0));

```

50

```

connect { agents      -> excessDemand
connect { excessDemand -> price
} mlp;

```

5

Mögliche Realisierung der Alternative des zweiten Ausführungsbeispiels:

1. Parameter-Datei:

```

10 BpNet {
11   Globals {
12     WtPenalty {
13       sel NoPenalty
14       Weigend {
15         Lambda { 0.000000 }
16         AutoAdapt { T }
17         w0 { 1.000000 }
18         DeltaLambda { 0.000001 }
19         ReducFac { 0.900000 }
20         Gamma { 0.900000 }
21         DesiredError { 0.000000 }
22       }
23       WtDecay {
24         Lambda { 0.010000 }
25         AutoAdapt { F }
26         AdaptTime { 10 }
27         EpsObj { 0.001000 }
28         ObjSet { Training }
29         EpsilonFac { 1.000000 }
30       }
31       ExtWtDecay {
32         Lambda { 0.001000 }
33         AutoAdapt { F }
34         AdaptTime { 10 }
35         EpsObj { 0.001000 }
36         ObjSet { Training }
37         EpsilonFac { 1.000000 }
38       }
39       Finnoff {
40         AutoAdapt { T }
41         Lambda { 0.000000 }
42         DeltaLambda { 0.000001 }
43         ReducFac { 0.900000 }
44         Gamma { 0.900000 }
45         DesiredError { 0.000000 }
46       }
47     }
48     ErrorFunc {
49       sel LnCosh
50       |x| {
51         parameter { 0.050000 }
52       }
53       LnCosh {
54         parameter { 2.000000 }
55       }
56     }
57     AnySave {
58       file_name { f.Globals.dat }
59     }
60     AnyLoad {
61       file_name { f.Globals.dat }
62     }
63     ASCII { T }
64   }
65   LearnCtrl {
66     sel Stochastic
67     Stochastic {
68       PatternSelection {
69         sel Permute
70         SubSample {
71           Percent { 0.500000 }
72         }
73       }
74     }
75   }
76 }

```

```

    }
    ExpRandom {
        Lambda { 2.000000 }
    }
5     }
    WtPruneCtrl {
        PruneSchedule {
            sel FixSchedule
            FixSchedule {
                Limit_0 { 10 }
                Limit_1 { 10 }
                Limit_2 { 10 }
                Limit_3 { 10 }
                RepeatLast { T }
            }
10    }
        DynSchedule {
            MaxLength { 4 }
            MinimumRuns { 0 }
            Training { F }
            Validation { T }
            Generalization { F }
        }
20    }
        DivSchedule {
            Divergence { 0.100000 }
            MinEpochs { 5 }
        }
25    }
        PruneAlg {
            sel FixPrune
            FixPrune {
                Perc_0 { 0.100000 }
                Perc_1 { 0.100000 }
                Perc_2 { 0.100000 }
                Perc_3 { 0.100000 }
            }
35    }
            EpsiPrune {
                DeltaEps { 0.050000 }
                StartEps { 0.050000 }
                MaxEps { 1.000000 }
                ReuseEps { F }
            }
40    }
        }
        Tracer {
            Active { F }
            Set { Validation }
            File { trace }
        }
45    }
        Active { F }
        Randomize { 0.000000 }
        PruningSet { Train.+Valid. }
        Method { S-Pruning }
    }
50    }
        StopControl {
            EpochLimit {
                Active { F }
                MaxEpoch { 60 }
            }
            MovingExpAverage {
                Active { F }
                MaxLength { 4 }
                Training { F }
                Validation { T }
                Generalization { F }
                Decay { 0.900000 }
            }
60    }
            CheckObjectiveFct {
                Active { F }
                MaxLength { 4 }
                Training { F }
                Validation { T }
                Generalization { F }
            }
70    }
            CheckDelta {
                Active { F }
                Divergence { 0.100000 }
            }
75    }
        }
        EtaCtrl {
    }

```

```

      Mode {
        sel EtaSchedule
        EtaSchedule {
          SwitchTime { 10 }
          ReductFactor { 0.950000 }
        }
        FuzzCtrl {
          MaxDeltaObj { 0.300000 }
          MaxDelta2Obj { 0.300000 }
          MaxEtaChange { 0.020000 }
          MinEta { 0.001000 }
          MaxEta { 0.100000 }
          Smoother { 1.000000 }
        }
        Active { F }
      }
      LearnAlgo {
        sel VarioEta
        VarioEta {
          MinCalls { 50 }
        }
        MomentumBackProp {
          Alpha { 0.050000 }
        }
        Quickprop {
          Decay { 0.050000 }
          Mu { 2.000000 }
        }
      }
      AnySave {
        file_name { f.Stochastic.dat }
      }
      AnyLoad {
        file_name { f.Stochastic.dat }
      }
      BatchSize { 10 }
      Eta { 0.010000 }
      DerivEps { 0.000000 }
    }
    TrueBatch {
      PatternSelection {
        sel Sequential
        SubSample {
          Percent { 0.500000 }
        }
        ExpRandom {
          Lambda { 2.000000 }
        }
      }
      WtPruneCtrl {
        Tracer {
          Active { F }
          Set { Validation }
          File { trace }
        }
        Active { F }
        Randomize { 0.000000 }
        PruningSet { Train.+Valid. }
        Method { S-Pruning }
      }
      EtaCtrl {
        Active { F }
      }
    }
    LearnAlgo {
      sel VarioEta
      VarioEta {
        MinCalls { 200 }
      }
      MomentumBackProp {
        Alpha { 0.050000 }
      }
      Quickprop {
        Decay { 0.050000 }
        Mu { 2.000000 }
      }
    }
    AnySave {

```

```
      file_name { f.TrueBatch.dat }
    }
  AnyLoad {
    file_name { f.TrueBatch.dat }
  }
  Eta { 0.050000 }
  DerivEps { 0.000000 }
}
LineSearch {
  PatternSelection {
    sel Sequential
    SubSample {
      Percent { 0.500000 }
    }
    ExpRandom {
      Lambda { 2.000000 }
    }
  }
  WtPruneCtrl {
    Tracer {
      Active { F }
      Set { Validation }
      File { trace }
    }
    Active { F }
    Randomize { 0.000000 }
    PruningSet { Train.+Valid. }
    Method { S-Pruning }
  }
  LearnAlgo {
    sel ConjGradient
    VarioEta {
      MinCalls { 200 }
    }
    MomentumBackProp {
      Alpha { 0.050000 }
    }
    Quickprop {
      Decay { 0.050000 }
      Mu { 2.000000 }
    }
    Low-Memory-BFGS {
      Limit { 2 }
    }
  }
  AnySave {
    file_name { f.LineSearch.dat }
  }
}
AnyLoad {
  file_name { f.LineSearch.dat }
}
EtaNull { 1.000000 }
MaxSteps { 10 }
LS_Precision { 0.500000 }
TrustRegion { T }
DerivEps { 0.000000 }
BatchSize { 2147483647 }
}
GeneticWeightSelect {
  PatternSelection {
    sel Sequential
    SubSample {
      Percent { 0.500000 }
    }
    ExpRandom {
      Lambda { 2.000000 }
    }
  }
}
LearnAlgo {
  sel VarioEta
  VarioEta {
    MinCalls { 200 }
  }
  MomentumBackProp {
    Alpha { 0.050000 }
  }
}
ObjFctTracer {
```

```

        Active { F }
        File { objFunc }
    }
5   SearchControl {
    SearchStrategy {
        sel HillClimberControl
        HillClimberControl {
            &InitialAlive { 0.950000 }
            InheritWeights { T }
10          Beta { 0.100000 }
            MutationType { DistributedMacroMutation }
            MaxTrials { 50 }
        }
        PBILControl {
            &InitialAlive { 0.950000 }
            InheritWeights { T }
            Beta { 0.100000 }
            Alpha { 0.100000 }
20          PopulationSize { 40 }
        }
        PopulationControl {
            pCrossover { 1.000000 }
            CrossoverType { SimpleCrossover }
            Scaling { T }
            ScalingFactor { 2.000000 }
            Sharing { T }
            SharingFactor { 0.050000 }
            PopulationSize { 50 }
            min.&InitialAlive { 0.010000 }
30          max.&InitialAlive { 0.100000 }
        }
        pMutation { 0.000000 }
    }
35   ObjectiveFunctionWeights {
        %Alive { 0.600000 }
        E(TS) { 0.200000 }
        Improvement(TS) { 0.000000 }
        E(VS) { 1.000000 }
40          Improvement(VS) { 0.000000 }
        (E(TS)-E(VS))/max(E(TS),E(VS)) { 0.000000 }
        LipComplexity { 0.000000 }
        OptComplexity { 2.000000 }
        testVal(dead)-testVal(alive) { 0.000000 }
    }
45   AnySave {
        file_name { f.GeneticWeightSelect.dat }
    }
50   AnyLoad {
        file_name { f.GeneticWeightSelect.dat }
    }
        Eta { 0.050000 }
        DerivEps { 0.000000 }
        BatchSize { 5 }
55          #minEpochsForFitnessTest { 2 }
          #maxEpochsForFitnessTest { 3 }
          SelectWeights { T }
          SelectNodes { T }
          maxGrowthOfValError { 0.005000 }
    }
60
}
CCMenu {
    Clusters {
        mlp.priceInput {
            ActFunction {
                sel id
                plogistic {
                    parameter { 0.500000 }
                }
                ptanh {
                    parameter { 0.500000 }
                }
                pid {
                    parameter { 0.500000 }
                }
            }
        }
70   InputModification {
            sel None
    }
}

```

```
5           AdaptiveUniformNoise {
          NoiseEta { 1.000000 }
          DampingFactor { 1.000000 }
      }
  10          AdaptiveGaussNoise {
          NoiseEta { 1.000000 }
          DampingFactor { 1.000000 }
      }
  15          FixedUniformNoise {
          SetNoiseLevel {
              NewNoiseLevel { 1.045229 }
          }
      }
  20          FixedGaussNoise {
          SetNoiseLevel {
              NewNoiseLevel { 1.045229 }
          }
      }
  25          SaveNoiseLevel {
             Filename { noise_level.dat }
          }
  30          LoadNoiseLevel {
             Filename { noise_level.dat }
          }
  35          SaveManipulatorData {
             Filename { inputManip.dat }
          }
  40          LoadManipulatorData {
             Filename { inputManip.dat }
          }
  45          mlp.input {
              ActFunction {
                  sel id
                  plogistic {
                      parameter { 0.500000 }
                  }
                  ptanh {
                      parameter { 0.500000 }
                  }
                  pid {
                      parameter { 0.500000 }
                  }
              }
  50          InputModification {
              sel None
              AdaptiveUniformNoise {
                  NoiseEta { 1.000000 }
                  DampingFactor { 1.000000 }
              }
              AdaptiveGaussNoise {
                  NoiseEta { 1.000000 }
                  DampingFactor { 1.000000 }
              }
  55          FixedUniformNoise {
              SetNoiseLevel {
                  NewNoiseLevel { 1.045229 }
              }
          }
  60          FixedGaussNoise {
              SetNoiseLevel {
                  NewNoiseLevel { 1.045229 }
              }
          }
  65          SaveNoiseLevel {
             Filename { noise_level.dat }
          }
  70          LoadNoiseLevel {
             Filename { noise_level.dat }
          }
  75          SaveManipulatorData {
             Filename { inputManip.dat }
          }
  80          LoadManipulatorData {
             Filename { inputManip.dat }
          }
```



```

1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
5 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
10 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
15 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
20 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
25 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
30 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
35 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
40 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
45 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
50 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
55 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
60 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
65 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
70 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
75 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000 1.000000
    }
    mlp.priceOutput {
        ActFunction {
            sel id
            plogistic {
                parameter { 0.500000 }
            }
            ptanh {
                parameter { 0.500000 }
            }
            pid {
                parameter { 0.500000 }
            }
        }
        ErrorFunc {
            sel none
            |x| {
                parameter { 0.050000 }
            }
            LnCosh {
                parameter { 2.000000 }
            }
        }
    }
    ToleranceFlag { F }
    Tolerance { 0.000000 }
    Weighting { 1.000000 }
}
}
45 Connectors {
    mlp.agents->excessDemand {
        WeightWatcher {
            Active { T }
            MaxWeight { 1.000000 }
            MinWeight { 1.000000 }
        }
        LoadWeightsLocal {
            Filename { std }
        }
        SaveWeightsLocal {
            Filename { std }
        }
        Alive { T }
        WtFreeze { T }
    }
    AllowGeneticOptimization { F }
    Penalty { NoPenalty }
    AllowPruning { F }
    EtaModifier { 1.000000 }
}
60
65
70
75
}
mlp.priceOutput->agents {
    WeightWatcher {
        Active { T }
        MaxWeight { -0.001000 }
        MinWeight { -2.000000 }
    }
    LoadWeightsLocal {
        Filename { std }
    }
    SaveWeightsLocal {
        Filename { std }
    }
    Alive { T }
    WtFreeze { F }
}

```

```

AllowGeneticOptimization { F }
Penalty { NoPenalty }
AllowPruning { F }
EtaModifier { 1.000000 }
5
} mlp.input->agents {
  WeightWatcher {
    Active { F }
    MaxWeight { 1.000000 }
    MinWeight { 0.000000 }
  }
  LoadWeightsLocal {
    Filename { std }
  }
10
  SaveWeightsLocal {
    Filename { std }
  }
  Alive { T }
  WtFreeze { F }
  AllowGeneticOptimization { F }
  Penalty { NoPenalty }
  AllowPruning { T }
  EtaModifier { 1.000000 }
20
}
25
  mlp.bias->agents {
    WeightWatcher {
      Active { F }
      MaxWeight { 1.000000 }
      MinWeight { 0.000000 }
    }
    LoadWeightsLocal {
      Filename { std }
    }
30
    SaveWeightsLocal {
      Filename { std }
    }
    Alive { T }
    WtFreeze { F }
    AllowGeneticOptimization { F }
    Penalty { NoPenalty }
    AllowPruning { F }
    EtaModifier { 1.000000 }
40
}
45
  mlp.priceInput->priceOutput {
    WeightWatcher {
      Active { F }
      MaxWeight { 1.000000 }
      MinWeight { 0.000000 }
    }
    LoadWeightsLocal {
      Filename { std }
    }
    SaveWeightsLocal {
      Filename { std }
    }
50
    Alive { T }
    WtFreeze { T }
    AllowGeneticOptimization { F }
    Penalty { NoPenalty }
    AllowPruning { F }
    EtaModifier { 1.000000 }
55
}
60
  mlp.excessDemand->priceOutput {
    WeightWatcher {
      Active { T }
      MaxWeight { -0.010000 }
      MinWeight { -0.010000 }
    }
    LoadWeightsLocal {
      Filename { std }
    }
    SaveWeightsLocal {
      Filename { std }
    }
70
    Alive { F }
    WtFreeze { T }
    AllowGeneticOptimization { F }
    Penalty { NoPenalty }
75
}

```

```

      AllowPruning { F }
      EtaModifier { 1.000000 }
    }
  5   mlp.priceOutput->priceOutput {
      WeightWatcher {
        Active { F }
        MaxWeight { 1.000000 }
        MinWeight { 0.000000 }
      }
    10  LoadWeightsLocal {
        Filename { std }
      }
      SaveWeightsLocal {
        Filename { std }
      }
    15  Alive { F }
      WtFreeze { T }
      AllowGeneticOptimization { F }
      Penalty { NoPenalty }
    20  AllowPruning { F }
      EtaModifier { 1.000000 }
    }
    25  AnySave {
        file_name { f.CCMenu.dat }
      }
      AnyLoad {
        file_name { f.CCMenu.dat }
      }
    30  }
      RecPar {
        decay_c { 1.000000 }
        delta_t { 1.000000 }
        epsilon { 0.001000 }
      35  max_iter { 30 }
        show { T }
        Reset_Errors { T }
      }
      TestRun {
        filename { Test }
        Part.Transformed { F }
      }
    40  Online {
        filename { Online.dat }
      }
    45  }
  }

```

2. Spezifikations-Datei:

APPLICATION Prognose

```

50 MODE DAY WEEK 5
      FROM 01.01.1991 TO MAX
55 TRAINING FROM 01.01.1991 TO 03.09.1996
      VALIDATION FROM 03.09.1995 TO 03.09.1996
60 INPUT
      BEGIN DEMUSD "DMARKER/USDOLLR"
      x = FILE data/dol.txt COLUMN 1
65      INPUT = scale((x - x(-1)) / x(-1))
      INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
    END
70

```

60

```

BEGIN JPYUSD "JAPAYEN/USDOLLR"
  x = FILE data/dol.txt COLUMN 2

  INPUT = scale((x - x(-1)) / x(-1))
5
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

10  BEGIN ECUS3M "EURO-CURRENCY (LDN) US$ 3 MONTHS - MIDDLE RATE"
  x = FILE data/dol.txt COLUMN 3

  INPUT = scale((x - x(-1)) / x(-1))
15  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

20  BEGIN ECWGM3M "EURO-CURRENCY (LDN) D-MARK 3 MONTHS - MIDDLE RATE"
  x = FILE data/dol.txt COLUMN 4

  INPUT = scale((x - x(-1)) / x(-1))
25  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

30  BEGIN AUSGVG4RY "US TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
  x = FILE data/dol.txt COLUMN 5

  INPUT = scale((x - x(-1)) / x(-1))
35  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

40  BEGIN ABDGVG4RY "BD TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
  x = FILE data/dol.txt COLUMN 6

  INPUT = scale((x - x(-1)) / x(-1))
45  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

50  BEGIN AJPGVG4RY "JP TOTAL 7-10 YEARS DS GOVT. INDEX - RED. YIELD"
  x = FILE data/dol.txt COLUMN 7

  INPUT = scale((x - x(-1)) / x(-1))
55  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

60  BEGIN TOTMKUSRI "US-DS MARKET - TOT RETURN IND"
  x = FILE data/dol.txt COLUMN 8

  INPUT = scale((x - x(-1)) / x(-1))
65  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

70  BEGIN TOTMKBDRI "GERMANY-DS MARKET - TOT RETURN IND"
  x = FILE data/dol.txt COLUMN 9

  INPUT = scale((x - x(-1)) / x(-1))
75  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
END

BEGIN NYFECRB "COMMODITY RESEARCH BUREAU INDEX-CRB - PRICE INDEX"
  x = FILE data/dol.txt COLUMN 10

  INPUT = scale((x - x(-1)) / x(-1))
  INPUT = scale((x - 2 * x(-1) + x(-2)) / x)

```

END

```

5      BEGIN GOLDBLN "GOLD BULLION $/TROY OUNCE"
          x = FILE data/dol.txt COLUMN 11

          INPUT = scale((x - x(-1)) / x(-1))

10     INPUT = scale((x - 2 * x(-1) + x(-2)) / x)
      END

```

15 TARGET CLUSTER mlp.excessDemand

```
BEGIN excessDemand  
    TARGET = 0  
END
```

TARGET CLUSTER $\pi_{\text{D}}(\text{agents})$

25 BEGIN agents behavior
x = FILE data/dol.txt COLUMN 1

TARGET = 100 * ln(x(1) / x)
TARGET = 100 * ln(x(1) / x)


```

TARGET = 100 * ln(x(1) / x)
5
TARGET = 100 * ln(x(1) / x)
10
TARGET = 100 * ln(x(1) / x)
15
TARGET = 100 * ln(x(1) / x)
20
END

TARGET CLUSTER mlp.priceOutput

25
BEGIN price
    x = FILE data/dol.txt COLUMN 1
    TARGET = 100 * ln(x(1) / x)
    ASSIGN TO channel
    END
30

SIGNAL

35
BEGIN hit rate = NORMSUM(signal)
    t = TARGET channel
    o = OUTPUT channel
    SIGNAL = IF t * o > 0 THEN 1 ELSE 0
    END
40

BEGIN Roi
    y = FILE data/dol.txt COLUMN 1
    o = OUTPUT channel
45
    SIGNAL = (y(1) / y - 1) * sign(o)
    END

50
BEGIN realized potential = Relsum(signal1, signal2)
    y = FILE data/dol.txt COLUMN 1
    o = OUTPUT channel
    SIGNAL = (y(1) / y - 1) * sign(o)
    SIGNAL = abs(y(1) / y - 1)
    END
55

60
BEGIN Backtransformation of forecasts
    y = FILE data/dol.txt COLUMN 1
    o = OUTPUT channel
    SIGNAL = y(1)
    SIGNAL = y * (1 + o / 100)
    END
65

70
BEGIN Buy & Hold
    y = FILE data/dol.txt COLUMN 1
    SIGNAL = y(1) / y - 1
    END
75

BEGIN Naiv Prognose
    y = FILE data/dol.txt COLUMN 1

```

```
SIGNAL = (y(1) / y - 1) * sign(y - y(-1))
END
```

3. Modell-Top-Datei:

```
5  net {
    cluster ( IN ) priceInput;
    cluster ( IN ) input;
    cluster ( OUT ) excessDemand;
    cluster ( OUT ) agents;
    cluster ( OUT ) priceOutput;
10
15
} mlp;
```

In diesem Dokument sind folgende Veröffentlichungen zitiert:

[1] S. Haykin, Neural Networks: A Comprehensive Foundation,
Mc Millan College Publishing Company,
5 ISBN 0-02-352761-7, S. 498-533, 1994.

[2] A. Zell, Simulation Neuronaler Netze, Addison-Wesley
Publishing Company, S.560-561, 1. Auflage, Bonn, 1994

Patentansprüche

1. Anordnung zur rechnergestützten Kompensation eines Un-
5 gleichgewichtszustands eines ersten technischen Systems,
- mit einem ersten neuronalen Netz, welches das erste techni-
sche System beschreibt;
- mit einem zweiten neuronalen Netz, welches ein zweites
technisches System beschreibt;
10 - bei der das erste und das zweite neuronale Netz derart mit-
einander verbunden sind, daß ein Ungleichgewichtszustand des
ersten technischen Systems durch das zweite neuronale Netz
kompensierbar ist.
- 15 2. Anordnung nach Anspruch 1,
bei der das erste neuronale Netz zumindest ein erstes Ein-
gangs-Rechenelement und ein erstes Ausgangs-Rechenelement
aufweist.
- 20 3. Anordnung nach Anspruch 1 oder 2,
bei der das zweite neuronale Netz zumindest ein zweites Ein-
gangs-Rechenelement und ein zweites Ausgangs-Rechenelement
aufweist.
- 25 4. Anordnung nach einem Ansprache 1 bis 3,
bei der zumindest ein Teil der Rechenelemente künstliche Neu-
ronen sind.
- 30 5. Anordnung nach einem der Ansprüche 1 bis 4,
bei der mindestens ein Teil von Verbindungen zwischen Re-
chenelementen variabel ausgestaltet ist.
- 35 6. Anordnung nach einem der Ansprüche 1 bis 5,
bei der zumindest Teile der Verbindungen gleiche Gewichtsver-
te aufweisen.
7. Anordnung nach einem der Ansprüche 1 bis 6,

bei der das erste technische System und das zweite technische System jeweils ein Teilsystem eines gemeinsamen Gesamtsystems sind.

5 8. Anordnung nach einem der Ansprüche 1 bis 6,
bei der das erste technische System und das zweite technische System identisch sind.

9. Anordnung nach Anspruch 7 oder 8,
10 eingesetzt zur Ermittlung einer Dynamik eines Systems.

10. Anordnung nach einem der Ansprüche 7 bis 9,
eingesetzt zu einer Prognose eines zukünftigen Zustands eines Systems.

15 11. Anordnung nach Anspruch 10,
eingesetzt zu einer Überwachung und/oder Steuerung eines Systems.

20 12. Anordnung nach Anspruch 11,
bei der das System ein chemischer Reaktor ist.

13. Verfahren zur rechnergestützten Kompensation eines Ungleichgewichtszustands eines ersten technischen Systems,
25 - bei dem einem ersten neuronalen Netz, welches das erste technische System beschreibt, eine erste Eingangsgröße zugeführt wird;
- bei dem für die erste Eingangsgröße unter Verwendung des ersten neuronalen Netzes eine erste Ausgangsgröße ermittelt wird, welche einen Ungleichgewichtszustand des ersten technischen Systems beschreibt;
30 - bei dem die erste Ausgangsgröße als eine zweite Eingangsgröße einem zweiten neuronalen Netz zugeführt wird, welches ein zweites technisches System beschreibt;
35 - bei dem für die zweite Eingangsgröße unter Verwendung des zweiten neuronalen Netzes eine zweite Ausgangsgröße, welche einen Zustand des zweiten technischen Systems beschreibt,

derart ermittelt wird, daß der Ungleichgewichtszustand des ersten technischen Systems durch das zweite neuronale Netz kompensiert wird.

- 5 14. Verfahren nach Anspruch 13,
bei dem des erste technische System und das zweite technische System jeweils ein Teilsystem eines gemeinsamen Gesamtsystems beschreiben.
- 10 15. Verfahren nach Anspruch 14,
bei dem unter Verwendung des Zustands des zweiten technischen Systems eine Dynamik des Gesamtsystems ermittelt wird.
- 15 16. Verfahren nach einem der Ansprüche 13 bis 15,
eingesetzt zu einer Prognose eines zukünftigen Zustands eines Systems.
- 20 17. Verfahren nach Anspruch 16,
eingesetzt zu einer Überwachung und/oder Steuerung eines Systems.
- 25 18. Computerprogramm-Erzeugnis, das ein computerlesbares Speichermedium umfaßt, auf dem ein Programm gespeichert ist, das es einem Computer ermöglicht, nachdem es in einen Speicher des Computer geladen worden ist, folgende Schritte durchzuführen zur rechnergestützten Kompensation eines Ungleichgewichtszustands eines ersten technischen Systems:
 - einem ersten neuronalen Netz, welches das erste technische System beschreibt, wird eine erste Eingangsgröße zugeführt;
 - für die erste Eingangsgröße wird unter Verwendung des ersten neuronalen Netzes eine erste Ausgangsgröße ermittelt, welche einen Ungleichgewichtszustand des ersten technischen Systems beschreibt;
 - die erste Ausgangsgröße wird als eine zweite Eingangsgröße einem zweiten neuronalen Netz zugeführt, welches ein zweites technisches System beschreibt;

- für die zweite Eingangsgröße wird unter Verwendung des zweiten neuronalen Netzes eine zweite Ausgangsgröße, welche einen Zustand des zweiten technischen Systems beschreibt, derart ermittelt, daß der Ungleichgewichtszustand des ersten 5 technischen Systems durch das zweite neuronale Netz kompensiert wird.

19. Computerlesbares Speichermedium, auf dem ein Programm gespeichert ist, das es einem Computer ermöglicht, nachdem es 10 in einen Speicher des Computer geladen worden ist, folgende Schritte durchzuführen zur rechnergestützten Kompensation eines Ungleichgewichtszustands eines ersten technischen Systems:

- einem ersten neuronalen Netz, welches das erste technische 15 System beschreibt, wird eine erste Eingangsgröße zugeführt;
- für die erste Eingangsgröße wird unter Verwendung des ersten neuronalen Netzes eine erste Ausgangsgröße ermittelt, welche einen Ungleichgewichtszustand des ersten technischen Systems beschreibt;
- die erste Ausgangsgröße wird als eine zweite Eingangsgröße einem zweiten neuronalen Netz zugeführt, welches ein zweites 20 technisches System beschreibt;
- für die zweite Eingangsgröße wird unter Verwendung des zweiten neuronalen Netzes eine zweite Ausgangsgröße, welche 25 einen Zustand des zweiten technischen Systems beschreibt, derart ermittelt, daß der Ungleichgewichtszustand des ersten technischen Systems durch das zweite neuronale Netz kompensiert wird.

Zusammenfassung

**Anordnung und Verfahren sowie Computerprogramm-Erzeugnis und computerlesbares Speichermedium zur rechnergestützten Kompen-
5 sation eines Ungleichgewichtszustands**

Bei der Anordnung und dem Verfahren zur rechnergestützten
Kompensation eines Ungleichgewichtszustands eines ersten
technischen Systems beschreibt ein erstes neuronales Netz das
10 erste technische System und ein zweites neuronales Netz ein
zweites technisches System. Das erste und das zweite neurona-
le Netz sind derart miteinander verbunden, daß ein Ungleich-
gewichtszustand des ersten technischen Systems durch das
zweite neuronale Netz kompensiert wird.

GR 99 P 2091

Fig. 1

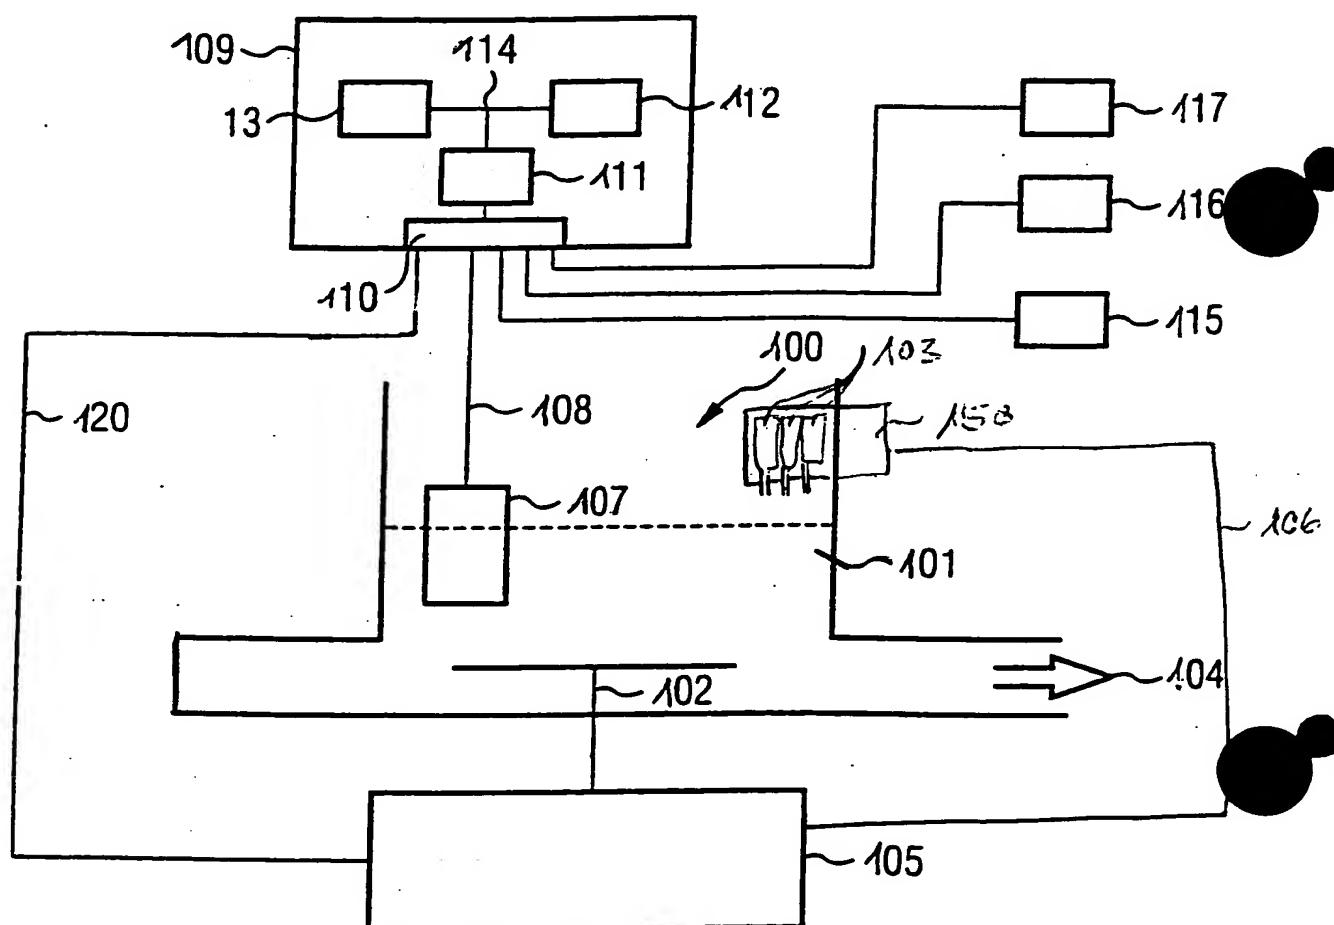
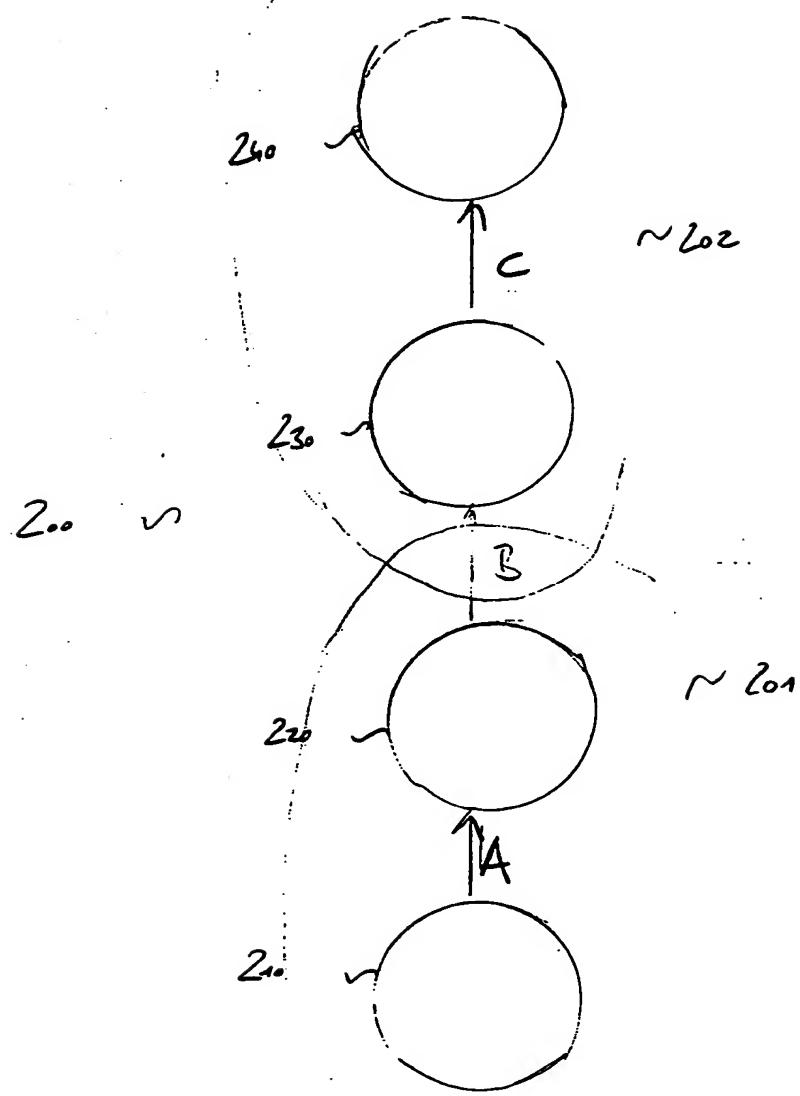
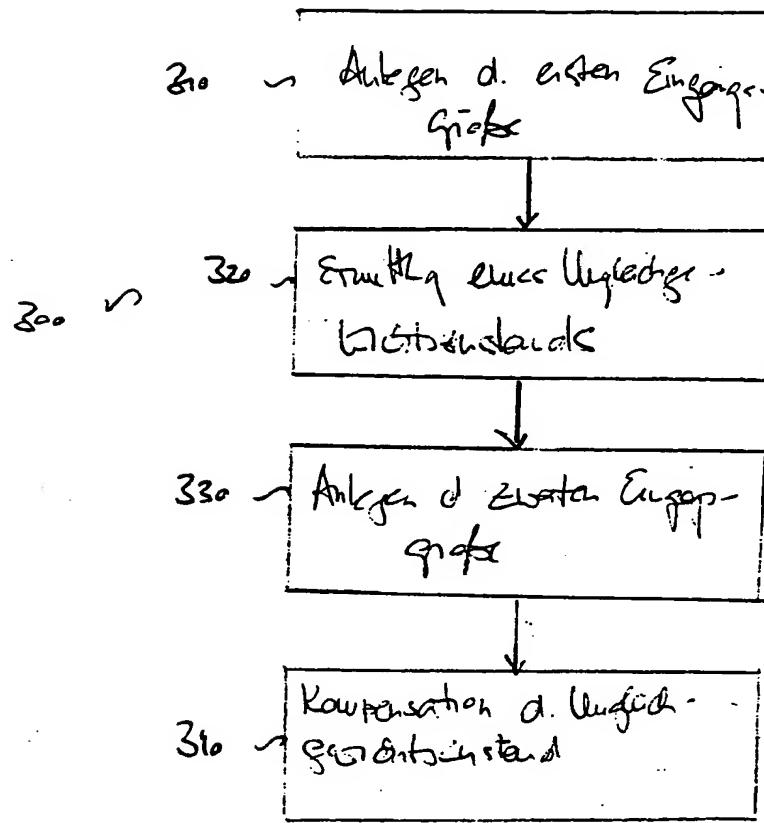
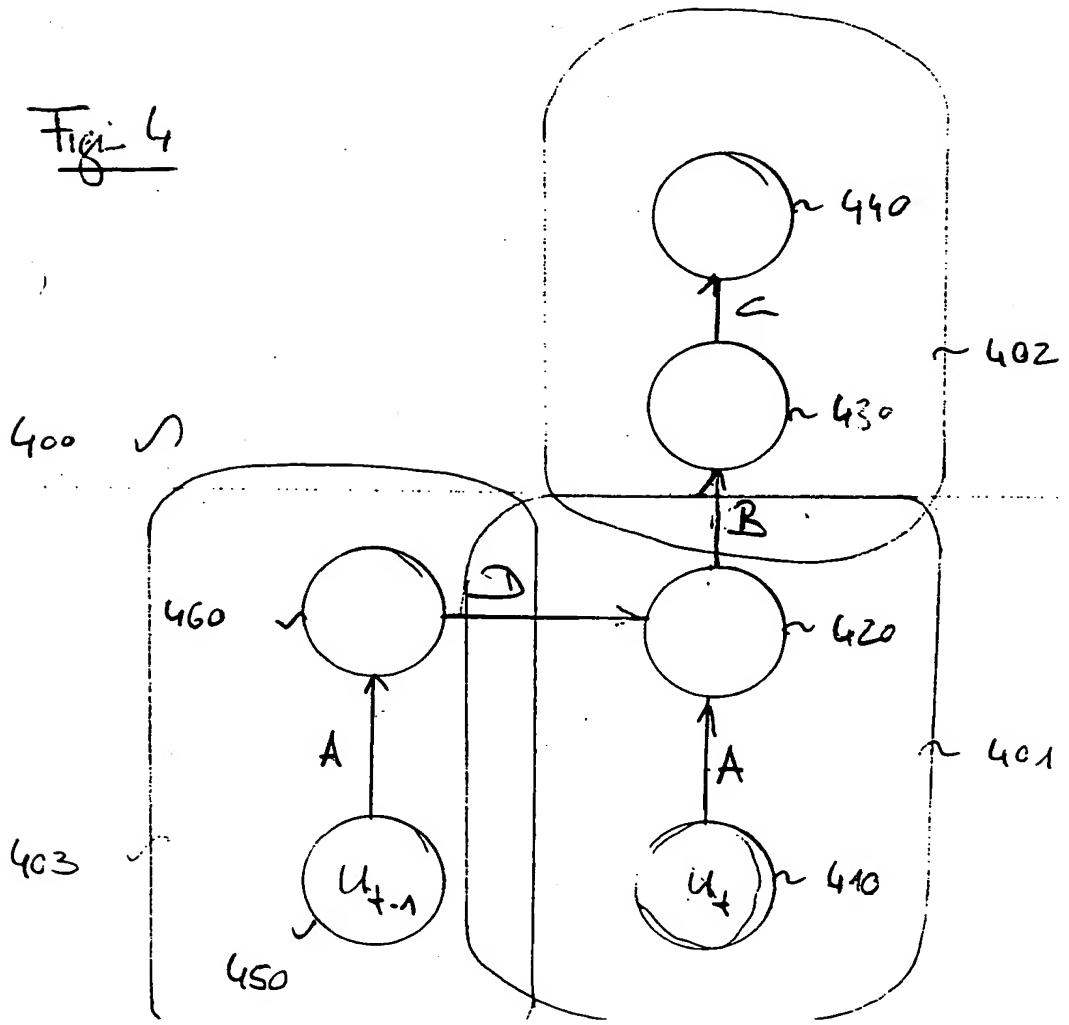


Fig 2



Figur 3Figur 4

Gr 99 P 2091

Fig 5

500 ✓

500 ✓

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

E

GR 99 T 2091

Fig 3:

